

**UNIVERSIDADE FEDERAL DE SANTA MARIA
CENTRO DE CIÊNCIAS RURAIS
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA AGRÍCOLA**

Tonismar dos Santos Pereira

**USO DE INTELIGÊNCIA ARTIFICIAL PARA ESTIMATIVA DA
CAPACIDADE DE SUPORTE DE CARGA DO SOLO**

Santa Maria, RS
2017

Tonismar dos Santos Pereira

**USO DE INTELIGÊNCIA ARTIFICIAL PARA ESTIMATIVA DA CAPACIDADE DE
SUPORTE DE CARGA DO SOLO**

Tese de Doutorado apresentada ao Programa de Pós-Graduação em Engenharia Agrícola, Área de Concentração Engenharia de Água e Solo, da Universidade Federal de Santa Maria (UFSM, RS), como requisito parcial para obtenção do grau de **Doutor em Engenharia Agrícola**.

Orientador: Prof. Dr. Adroaldo Dias Robaina

Santa Maria, RS
2017

Ficha catalográfica elaborada através do Programa de Geração Automática da Biblioteca Central da UFSM, com os dados fornecidos pelo(a) autor(a).

Pereira, Tonismar dos Santos
Uso de inteligência artificial para estimativa da capacidade de suporte de carga do solo / Tonismar dos Santos Pereira.- 2017.
179 p.; 30 cm

Orientador: Adroaldo Dias Robaina
Tese (doutorado) - Universidade Federal de Santa Maria, Centro de Ciências Rurais, Programa de Pós-Graduação em Engenharia Agrícola, RS, 2017

1. Pedofunções 2. Compactação do solo 3. Redes neurais artificiais 4. Máquinas de vetores de suporte 5. Inteligência artificial I. Robaina, Adroaldo Dias II. Título.

©2017

Todos os direitos reservados a Tonismar dos Santos Pereira. A reprodução de partes ou do todo deste trabalho só poderá ser feita mediante a citação da fonte.

Email: tonismarpereira@gmail.com

Tonismar dos Santos Pereira

**USO DE INTELIGÊNCIA ARTIFICIAL PARA ESTIMATIVA DA CAPACIDADE DE
SUPORTE DE CARGA DO SOLO**

Tese de Doutorado apresentada ao Programa de Pós-Graduação em Engenharia Agrícola, Área de Concentração Engenharia de Água e Solo, da Universidade Federal de Santa Maria (UFSM, RS), como requisito parcial para obtenção do grau de **Doutor em Engenharia Agrícola**.

Aprovado em 13 de fevereiro de 2017:

Adroaldo Dias Robaina, Dr. (UFSM)
(Presidente/Orientador)

Marcia Xavier Peiter, Dr^a. (UFSM)
(Co-orientadora)

Paulo Roberto da Costa, Dr. (UFSM)

Luciana Marini Kopp, Dr^a. (UFPel)

Gisele Aparecida Vivan, Dr^a. (IFSul-Bagé)

Leonita Beatriz Girardi, Dr^a.(URI-Santo Ângelo)

Santa Maria, RS
2017

AGRADECIMENTOS

A Deus, que ilumina e conforta em todos os momentos difíceis.

À Universidade Federal de Santa Maria, mais especificamente ao Programa de Pós-Graduação em Engenharia Agrícola (PPGEA), pela oportunidade oferecida.

Ao orientador Prof. Adroaldo Dias Robaina pela oportunidade, orientação, dedicação, amizade, confiança depositada e pelos ensinamentos e lições vivenciados durante este período.

A co-orientadora Prof^a Marcia Xavier Peiter, pelo constante acompanhamento, carinho, amizade, paciência, ensinamentos e auxílio na realização deste e de outros trabalhos.

Aos membros da Comissão Examinadora.

Aos funcionários do Departamento de Engenharia Rural, em especial ao Sr. Luiz Carlos Nunes pela dedicação e amizade.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pela bolsa de estudos concedida.

Aos professores do PPGEA pelos ensinamentos.

À minha esposa Juliane Diniz e filha Isabela Diniz Pereira, pelo incentivo, amor, carinho, motivação e compreensão para que mais esta meta fosse alcançada.

Aos meus pais, Antônio Pereira e Zaira Pereira, pelo amor, incentivo e dedicação em todos os momentos de minha vida.

Ao meu irmão Vagner Pereira e cunhada Flávia Pereira, pelo carinho e ajuda neste caminho percorrido.

À minha avó de coração Iolanda Diniz e sogro Julio Moacir Silveira Diniz pelo carinho e apoio durante este período.

Aos colegas e amigos Rogério Torres, Ricardo Rosso, Taise Buske, Fabiano Braga, Fátima Cibele Soares, Mario Nunes, Jardel Kirchner, Anderson Crestani, Luis Humberto Ben, Wellington Mezzomo, Cícero Urbaneto Nogueira e, principalmente, aos amigos que motivaram esta caminhada Gisele Vivan e Fabrício Barboza.

À memória do meu amigo Hendrigo Torchelsen da Silveira, pelo incentivo a retomar os estudos.

Aos amigos Clóvis Gonçalves da Silva e Ricardo Gonçalves da Silva pelo grande incentivo dado em minha jornada acadêmica.

A todos os amigos, que souberam entender minha ausência e que estiveram ao meu lado durante esta jornada incentivando.

Muito Obrigado!

“Cada homem que encontro é superior a mim em alguma coisa; e nisto posso aprender com ele. Está aí a sapiência da humildade e a humildade da verdadeira sabedoria”

(Dale Carnegie).

RESUMO

Tese de Doutorado
Programa de Pós-Graduação em Engenharia Agrícola
Universidade Federal de Santa Maria

USO DE INTELIGÊNCIA ARTIFICIAL PARA ESTIMATIVA DA CAPACIDADE DE SUPORTE DE CARGA DO SOLO

AUTOR: TONISMAR DOS SANTOS PEREIRA

ORIENTADOR: ADROALDO DIAS ROBAINA

Santa Maria, 13 de FEVEREIRO de 2017.

O conhecimento das relações entre propriedades físicas e mecânicas do solo pode contribuir no desenvolvimento de funções de pedotransferência (FPTs), que permitam estimar outras propriedades do solo de difícil mensuração. Os objetivos deste trabalho foram estimar a pressão de preconsolidação e a resistência do solo à penetração, com o uso de metodologias de predição, utilizando-se de dados disponíveis na literatura, com valores de características físico-hídricas e mineralógicas dos solos. Os valores estimados foram obtidos a partir de três métodos de modelagem: (i) regressão linear múltipla (RLM), (ii) redes neurais artificiais (RNA) e (iii) máquinas de vetores de suporte (MVS). A primeira metodologia proposta para o desenvolvimento dos modelos preditivos foi a opção *stepwise* do software IBM-SPSS 20.0®. Os modelos geradas a partir da segunda metodologia, ou seja, das RNA foram implementadas através do perceptron multicamadas com algoritmo backpropagation e otimização Levenberg-Marquardt do software Matlab®2008b, efetuando-se variações do número de neurônios na camada de entrada e número de neurônios na camada intermediária. A terceira metodologia foi gerar FPTs a partir de MVS que se enquadra dentro dos processos de mineração de dados utilizando para tal o software Waikato Environment for Knowledge Analysis® (RapidMiner 5). O treinamento das MVS foi realizado variando-se o número de dados de entrada, a função kernel e coeficientes destas funções. Realizadas as estimativas, foram calculados os índices de desempenho (id) e classificados segundo Camargo e Sentelhas (1997), podendo-se assim comparar os métodos entre si e a outros já consagrados. Os resultados obtidos mostraram que modelos de inteligência artificial (RNA e MVS) são eficientes e possuem capacidade preditiva superior aos modelos consagrados, em condições de dados de solos com classes texturais e manejos diversos, e semelhantes ainda que com valores de índice de desempenho superiores para condições de solos de mesma classe textural expostos ao mesmo manejo.

Palavras-chave: Pedofunções. Compactação do solo. Redes neurais artificiais. Máquinas de vetores de suporte. Inteligência artificial.

ABSTRACT

Doctoral Thesis
Agricultural Engineering Post Graduation Program
Santa Maria Federal University, RS, Brazil

USE OF ARTIFICIAL INTELLIGENCE TO SOIL LOAD SUPPORT CAPACITY ESTIMATE

AUTHOR: TONISMAR DOS SANTOS PEREIRA
ADVISER: ADROALDO DIAS ROBAINA
Santa Maria, February 13th, 2017.

The knowledge of the relationships between physical and mechanical properties of the soil may contribute to the development of pedotransfer functions (PTFs), to estimate other soil properties are difficult to measure. The objectives of this work were to estimate the preconsolidation pressure and soil resistance to penetration, using predictive methodologies, using data available in the literature, with physical-hydrological and mineralogical characteristics of soils. The development of PTFs was based on three modeling methods: (i) multiple linear regression (MLR), (ii) artificial neural networks (ANNs) and (iii) support vector machines (SVM). The first proposed methodology for the development of PTFs was the stepwise option of the IBM-SPSS 20.0® software. The models generated from the second methodology, ie RNA were implemented through the multilayer perceptron with backpropagation algorithm and Levenberg-Marquardt optimization of Matlab®2008b software, with variations of the number of neurons in the input layer and number of neurons In the middle layer. The third methodology was to generate PTFs from SVM that fit within the data mining process by exercising the Waikato Environment for Knowledge Analysis software (RapidMiner 5). The SVM training was performed by varying the number of input data, the kernel function and coefficients of these functions. Once the estimates were made, the performance indices (id) and classified according to Camargo and Sentelhas (1997) were calculated, thus comparing the methods between themselves and others already established. The obtained results showed that artificial intelligence models (RNA and MVS) are efficient and have predictive capacity superior to the established models, in data conditions of soils with textural classes and diverse managements, and similar, although with higher performance index values for Conditions of soils of the same textural class exposed to the same management.

Keywords: Pedofunctions. Soil compaction. Artificial neural networks. Support vector machine. Artificial intelligence.

LISTA DE FIGURAS

Figura 1 - Esquema ilustrativo da determinação da pressão de preconsolidação obtido da curva de compressão pelo método de Casagrande	40
Figura 2 - Representação do relacionamento entre variáveis de um processo	44
Figura 3 - Modelo matemático de neurônio artificial	48
Figura 4 - Representação de rede neural única camada.....	51
Figura 5 - Representação de rede neural com múltiplas camadas.....	52
Figura 6 - Representação de rede neural recorrente.....	53
Figura 7 - Diagrama em blocos da aprendizagem supervisionada.....	55
Figura 8 - Estrutura de rede neural do tipo perceptron de única camada.....	57
Figura 9 - Rede neural artificial multicamadas (Multilayer Perceptron)	58
Figura 10 - Fluxo do algoritmo Back-propagation.....	60
Figura 11 - Exemplo de transformação MVS.....	62
Figura 12 - Esquema da geração de um classificador.....	66
Figura 13 - Diferentes hipóteses de configuração de treinamento	67
Figura 14 - Separação por hiperplanos de margem máxima.....	69
Figura 15 - Representação de emprego de Função circular (a) e Função linear em R^3 (b).....	72
Figura 16 - Mudança do espaço original para o de características	73
Figura 17 - Fluxograma da modelagem computacional.....	80
Figura 18 - Arquitetura da rede neural utilizada.....	87
Figura 19 - Representação gráfica dos valores de RP e σ_p observados na literatura em relação aos estimados por regressão linear múltipla no modelo RLM1	98
Figura 20 - Representação gráfica dos valores de RP e σ_p observados na literatura em relação aos estimados por regressão linear múltipla no modelo RLM2.....	100
Figura 21 - Representação gráfica dos valores de RP e σ_p observados na literatura em relação aos estimados por regressão linear múltipla no modelo RLM3.....	101
Figura 22 - Representação gráfica dos valores de RP e σ_p observados na literatura em relação aos estimados por regressão linear múltipla no modelo RLM4.....	103
Figura 23 - Representação gráfica dos valores de RP e σ_p observados na literatura em relação aos estimados por regressão linear múltipla no modelo RLM5.....	104
Figura 24 - Representação gráfica dos valores de RP e σ_p observados na literatura em relação aos estimados por regressão linear múltipla no modelo RLM6.....	106

Figura 25 - Representação gráfica dos valores de RP e σ_p observados na literatura em relação aos estimados por regressão linear múltipla no modelo RLM7	107
Figura 26 - Representação gráfica dos valores de RP e σ_p observados na literatura em relação aos estimados por regressão linear múltipla no modelo RLM8	108
Figura 27 - Representação gráfica dos valores de RP e σ_p observados na literatura em relação aos estimados por regressão linear múltipla no modelo RLM9	110
Figura 28 - Representação gráfica dos valores de RP e σ_p observados na literatura em relação aos estimados por regressão linear múltipla no modelo RLM10	111
Figura 29 - Representação gráfica dos valores de RP e σ_p observados na literatura em relação aos estimados por regressão linear múltipla no modelo RLM11	113
Figura 30 - Representação gráfica dos valores de RP e σ_p observados na literatura em relação aos estimados por regressão linear múltipla no modelo RLM12	114
Figura 31 - Representação gráfica dos valores de RP e σ_p observados na literatura em relação aos estimados por regressão linear múltipla no modelo RLM13	115
Figura 32 - Representação gráfica dos valores de RP e σ_p observados na literatura em relação aos estimados por redes neurais artificiais no modelo RNA1	117
Figura 33 - Representação gráfica dos valores de RP e σ_p observados na literatura em relação aos estimados por redes neurais artificiais no modelo RNA2	118
Figura 34 - Representação gráfica dos valores de RP e σ_p observados na literatura em relação aos estimados por redes neurais artificiais no modelo RNA3	119
Figura 35 - Representação gráfica dos valores de RP e σ_p observados na literatura em relação aos estimados por redes neurais artificiais no modelo RNA4	120
Figura 36 - Representação gráfica dos valores de RP e σ_p observados na literatura em relação aos estimados por redes neurais artificiais no modelo RNA5	121
Figura 37 - Representação gráfica dos valores de RP e σ_p observados na literatura em relação aos estimados por redes neurais artificiais no modelo RNA6	122
Figura 38 - Representação gráfica dos valores de RP e σ_p observados na literatura em relação aos estimados por redes neurais artificiais no modelo RNA7	123

Figura 39 - Representação gráfica dos valores de RP e σ_p observados na literatura em relação aos estimados por redes neurais artificiais no modelo RNA8	124
Figura 40 - Representação gráfica dos valores de RP e σ_p observados na literatura em relação aos estimados por redes neurais artificiais no modelo RNA9	125
Figura 41 - Representação gráfica dos valores de RP e σ_p observados na literatura em relação aos estimados por redes neurais artificiais no modelo RNA10	126
Figura 42 - Representação gráfica dos valores de RP e σ_p observados na literatura em relação aos estimados por redes neurais artificiais no modelo RNA11	127
Figura 43 - Representação gráfica dos valores de RP e σ_p observados na literatura em relação aos estimados por redes neurais artificiais no modelo RNA12	127
Figura 44 - Representação gráfica dos valores de RP e σ_p observados na literatura em relação aos estimados por redes neurais artificiais no modelo RNA13	128
Figura 45 - Representação gráfica dos valores de RP observados na literatura em relação aos estimados por redes neurais artificiais no modelo RNA-FA1	129
Figura 46 - Representação gráfica dos valores de RP observados na literatura em relação aos estimados por redes neurais artificiais no modelo RNA-FA2	130
Figura 47 - Representação gráfica dos valores de RP observados na literatura em relação aos estimados por redes neurais artificiais no modelo RNA-MA	131
Figura 48 - Representação gráfica dos valores de RP e σ_p observados na literatura em relação aos estimados por máquinas de vetores de suporte no modelo MVS1	133
Figura 49 - Representação gráfica dos valores de RP e σ_p observados na literatura em relação aos estimados por máquinas de vetores de suporte no modelo MVS2	134
Figura 50 - Representação gráfica dos valores de RP e σ_p observados na literatura em relação aos estimados por máquinas de vetores de suporte no modelo MVS3	135
Figura 51 - Representação gráfica dos valores de RP e σ_p observados na literatura em relação aos estimados por máquinas de vetores de suporte no modelo MVS4	136
Figura 52 - Representação gráfica dos valores de RP e σ_p observados na literatura em relação aos estimados por máquinas de vetores de suporte no modelo MVS5	137

Figura 53 - Representação gráfica dos valores de RP e σ_p observados na literatura em relação aos estimados por máquinas de vetores de suporte no modelo MVS6	138
Figura 54 - Representação gráfica dos valores de RP e σ_p observados na literatura em relação aos estimados por máquinas de vetores de suporte no modelo MVS7	139
Figura 55 - Representação gráfica dos valores de RP e σ_p observados na literatura em relação aos estimados por máquinas de vetores de suporte no modelo MVS8	140
Figura 56 - Representação gráfica dos valores de RP e σ_p observados na literatura em relação aos estimados por máquinas de vetores de suporte no modelo MVS9	141
Figura 57 - Representação gráfica dos valores de RP e σ_p observados na literatura em relação aos estimados por máquinas de vetores de suporte no modelo MVS10	142
Figura 58 - Representação gráfica dos valores de RP e σ_p observados na literatura em relação aos estimados por máquinas de vetores de suporte no modelo MVS11	143
Figura 59 - Representação gráfica dos valores de RP e σ_p observados na literatura em relação aos estimados por máquinas de vetores de suporte no modelo MVS12	143
Figura 60 - Representação gráfica dos valores de RP e σ_p observados na literatura em relação aos estimados por máquinas de vetores de suporte no modelo MVS13	144
Figura 61 - Representação gráfica dos valores de RP observados na literatura em relação aos estimados por redes neurais artificiais no modelo MVS-FA1	145
Figura 62 - Representação gráfica dos valores de RP observados na literatura em relação aos estimados por redes neurais artificiais no modelo MVS-FA2	146
Figura 63 - Representação gráfica dos valores de RP observados na literatura em relação aos estimados por redes neurais artificiais no modelo MVS-MA	147

LISTA DE TABELAS

Tabela 1 - Modelos utilizados para descrever resultados obtidos nos ensaios de compressão uniaxial.....	41
Tabela 2 - Funções de ativação e suas representações gráficas.....	50
Tabela 3 - Tipos de funções kernel	76
Tabela 4 - Variáveis independentes de entrada nos modelos computacionais de estimativa de resistência à penetração (RP) e pressão de preconsolidação (σ_p).	82
Tabela 5 - Nomenclatura dos modelos de entrada em cada metodologia aplicada.....	83
Tabela 6 - Número de amostras utilizadas para obtenção da resistência à penetração (RP) e pressão de preconsolidação (σ_p)	84
Tabela 7 - Valores máximos, mínimos, médios, desvio padrão e coeficiente de variação (CV) das variáveis utilizadas nos modelos de Resistência à Penetração (RP) do banco de dados geral	84
Tabela 8 - Valores máximos, mínimos, médios, desvio padrão e coeficiente de variação (CV) das variáveis utilizadas nos modelos de Pressão de Preconsolidação (σ_p) do banco de dados geral.....	85
Tabela 9 - Classificação do índice de desempenho (<i>id</i>).....	90
Tabela 10 - Coeficiente de correlação (r) entre as variáveis independentes e dependentes para as Regressões Lineares Múltiplas.....	92
Tabela 11 - Coeficientes das equações de regressão linear múltipla e de determinação para estimativa da resistência à penetração e da pressão de preconsolidação para a RLM 1	97
Tabela 12 - Coeficientes das equações de regressão linear múltipla e de determinação para estimativa da resistência à penetração e da pressão de preconsolidação para a RLM 2.....	99
Tabela 13 - Coeficientes das equações de regressão linear múltipla e de determinação para estimativa da resistência à penetração e da pressão de preconsolidação para a RLM 3.....	101
Tabela 14 - Coeficientes das equações de regressão linear múltipla e de determinação para estimativa da resistência à penetração e da pressão de preconsolidação para a RLM4.....	102
Tabela 15 - Coeficientes das equações de regressão linear múltipla e de determinação para estimativa da resistência à penetração e da pressão de preconsolidação para a RLM5.....	104
Tabela 16 - Coeficientes das equações de regressão linear múltipla e de determinação para estimativa da resistência à penetração e da pressão de preconsolidação para a RLM6.....	105

Tabela 17 - Coeficientes das equações de regressão linear múltipla e de determinação para estimativa da resistência à penetração e da pressão de preconsolidação para a RLM7	106
Tabela 18 - Coeficientes das equações de regressão linear múltipla e de determinação para estimativa da resistência à penetração e da pressão de preconsolidação para a RLM8	108
Tabela 19 - Coeficientes das equações de regressão linear múltipla e de determinação para estimativa da resistência à penetração e da pressão de preconsolidação para a RLM9	109
Tabela 20 - Coeficientes das equações de regressão linear múltipla e de determinação para estimativa da resistência à penetração e da pressão de preconsolidação para a RLM10	111
Tabela 21 - Coeficientes das equações de regressão linear múltipla e de determinação para estimativa da resistência à penetração e da pressão de preconsolidação para a RLM11	112
Tabela 22 - Coeficientes das equações de regressão linear múltipla e de determinação para estimativa da resistência à penetração e da pressão de preconsolidação para a RLM12	114
Tabela 23 - Coeficientes das equações de regressão linear múltipla e de determinação para estimativa da resistência à penetração e da pressão de preconsolidação para a RLM13	115
Tabela 24 - Valores do coeficiente de correlação (r), coeficiente de determinação (R ²), índice de concordância (c), índice de desempenho (id) e a classe de desempenho qualitativo dos diferentes modelos de RLM para estimativa da resistência do solo à penetração (RP).....	148
Tabela 25 - Valores do coeficiente de correlação (r), coeficiente de determinação (R ²), índice de concordância (c), índice de desempenho (id) e a classe de desempenho qualitativo dos diferentes modelos de RLM para estimativa da pressão de preconsolidação do solo (σ_p)	149
Tabela 26 - Valores do coeficiente de correlação (r), coeficiente de determinação (R ²), índice de concordância (c), índice de desempenho (id) e a classe de desempenho qualitativo dos diferentes modelos de RNA para estimativa da resistência do solo à penetração (RP).....	150
Tabela 27 - Valores do coeficiente de correlação (r), coeficiente de determinação (R ²), índice de concordância (c), índice de desempenho (id) e a classe de desempenho qualitativo dos diferentes modelos de RNA para estimativa da pressão de preconsolidação do solo (σ_p)	151
Tabela 28 - Valores do coeficiente de correlação (r), coeficiente de determinação (R ²), índice de concordância (c), índice de desempenho (id) e a classe de desempenho qualitativo dos diferentes modelos de MVS para estimativa da resistência do solo à penetração (RP).....	152

Tabela 29 - Valores do coeficiente de correlação (r), coeficiente de determinação (R ²), índice de concordância (c), índice de desempenho (id) e a classe de desempenho qualitativo dos diferentes modelos de MVS para estimativa da pressão de preconsolidação do solo (σ_p)	153
Tabela 30 - Valores do coeficiente de correlação (r), coeficiente de determinação (R ²), índice de concordância (c), índice de desempenho (id) e a classe de desempenho qualitativo dos diferentes modelos de estimativa da resistência do solo à penetração (RP)	154
Tabela 31 - Valores do coeficiente de correlação (r), coeficiente de determinação (R ²), índice de concordância (c), índice de desempenho (id) e a classe de desempenho qualitativo dos diferentes modelos de estimativa da resistência do solo à penetração (RP) da arquitetura M13	155
Tabela 32 - Valores do coeficiente de correlação (r), coeficiente de determinação (R ²), índice de concordância (c), índice de desempenho (id) e a classe de desempenho qualitativo dos diferentes modelos de estimativa da resistência do solo à penetração (RP) para solo franco arenoso (FA1)	156
Tabela 33 - Valores do coeficiente de correlação (r), coeficiente de determinação (R ²), índice de concordância (c), índice de desempenho (id) e a classe de desempenho qualitativo dos diferentes modelos de estimativa da resistência do solo à penetração (RP) para solo franco arenoso (FA2)	157
Tabela 34 - Valores do coeficiente de correlação (r), coeficiente de determinação (R ²), índice de concordância (c), índice de desempenho (id) e a classe de desempenho qualitativo dos diferentes modelos de estimativa da resistência do solo à penetração (RP) para solo muito argiloso (MA)	157
Tabela 35 - Valores do coeficiente de correlação (r), coeficiente de determinação (R ²), índice de concordância (c), índice de desempenho (id) e a classe de desempenho qualitativo dos diferentes modelos de estimativa da pressão de preconsolidação do solo (σ_p)	158
Tabela 36 - Valores do coeficiente de correlação (r), coeficiente de determinação (R ²), índice de concordância (c), índice de desempenho (id) e a classe de desempenho qualitativo dos diferentes modelos de estimativa da pressão de preconsolidação do solo (σ_p) vs o método de Dias Junior e Pierce (1995) para solo muito argiloso (MA)	159

SUMÁRIO

1	INTRODUÇÃO.....	27
1.1	OBJETIVO GERAL	29
1.2	OBJETIVOS ESPECÍFICOS	30
2	REVISÃO DE LITERATURA	31
2.1	COMPACTAÇÃO DO SOLO.....	31
2.2	CONSOLIDAÇÃO DO SOLO	32
2.3	CAPACIDADE DE SUPORTE DE CARGA DO SOLO.....	33
2.4	PRESSÃO DE PRECONSOLIDAÇÃO.....	34
2.5	RESISTÊNCIA DO SOLO À PENETRAÇÃO	35
2.6	MÉTODOS PARA OBTENÇÃO DA CAPACIDADE DE SUPORTE DE CARGA DO SOLO	36
2.6.1	Métodos diretos	37
2.6.1.1	Métodos diretos de obtenção da resistência do solo à penetração	37
2.6.1.2	Métodos diretos de obtenção da pressão de preconsolidação.....	38
2.6.2	Métodos indiretos	39
2.6.2.1	Métodos indiretos de obtenção da resistência à penetração.....	39
2.6.2.2	Métodos indiretos de obtenção da pressão de preconsolidação	40
2.6.2.3	Funções de pedotransferência	42
2.6.2.4	Aprendizado de Máquina (AM)	43
2.6.2.4.1	Regressão Linear Múltipla (RLM).....	44
2.6.2.4.2	Redes Neurais Artificiais (RNA)	46
2.6.2.4.2.1	O neurônio Artificial	48
2.6.2.4.2.2	Função de ativação	49
2.6.2.4.2.3	Arquitetura da rede neural artificial.....	50
2.6.2.4.2.3.1	Redes Feedforward (Única Camada).....	51
2.6.2.4.2.3.2	Redes Feedforward (Multicamadas)	52
2.6.2.4.2.4	Aprendizagem da RNA.....	53

2.6.2.4.2.5	Modelos de Aprendizagem	56
2.6.2.4.2.6	Redes Perceptron	56
2.6.2.4.2.7	Rede Perceptron de Múltiplas Camadas (MLP).....	57
2.6.2.4.3	Máquinas de vetores de suporte (MVS).....	61
2.6.2.4.3.1	Histórico das MVS	63
2.6.2.4.3.2	Aprendizado com MVS	65
2.6.2.4.3.3	Teoria do aprendizado estatístico (TAE).....	65
2.6.2.4.3.4	Risco.....	67
2.6.2.4.3.5	Classificação com MVS	68
2.6.2.4.3.6	MVS com margens suaves	71
2.6.2.4.3.7	Regressão com MVS	72
2.6.2.4.3.8	Funções kernel	75
3	MATERIAIS E MÉTODOS	79
3.1	DESCRIÇÃO DO ESTUDO	79
3.2	BASE DE DADOS	81
3.3	SELEÇÃO DAS VARIÁVEIS NA CAMADA DE ENTRADA	81
3.4	FERRAMENTAS UTILIZADAS	85
3.5	ESTIMATIVA DA CAPACIDADE DE CARGA DO SOLO UTILIZANDO RLM	86
3.6	ESTIMATIVA DA CAPACIDADE DE CARGA DO SOLO UTILIZANDO RNA.	86
3.6.1	Número de camadas escondidas e número de neurônios das RNA.....	86
3.6.2	Definição do treinamento da rede neural e avaliação do desempenho.....	87
3.7	ESTIMATIVA DA CAPACIDADE DE CARGA DO SOLO UTILIZANDO MVS	88
3.7.1	Definição da função kernel e dos parâmetros de entrada da MVS	88
3.8	ANÁLISE DE DADOS	89
4	RESULTADOS E DISCUSSÃO	91

4.1	VALORES ESTIMADOS POR REGRESSÃO LINEAR MÚLTIPLA (RLM)...	91
4.1.1	Correlação entre variáveis independentes e os indicadores de capacidade de suporte de carga do solo.....	91
4.1.2	Estimativa dos indicadores de capacidade de suporte de carga – RLM1.....	97
4.1.3	Estimativa dos indicadores de capacidade de suporte de carga – RLM2.....	99
4.1.4	Estimativa dos indicadores de capacidade de suporte de carga – RLM3...	100
4.1.5	Estimativa dos indicadores de capacidade de suporte de carga – RLM4...	102
4.1.6	Estimativa dos indicadores de capacidade de suporte de carga – RLM5...	103
4.1.7	Estimativa dos indicadores de capacidade de suporte de carga – RLM6...	105
4.1.8	Estimativa dos indicadores de capacidade de suporte de carga – RLM7...	106
4.1.9	Estimativa dos indicadores de capacidade de suporte de carga – RLM8...	108
4.1.10	Estimativa dos indicadores de capacidade de suporte de carga – RLM9...	109
4.1.11	Estimativa dos indicadores de capacidade de suporte de carga – RLM10.	110
4.1.12	Estimativa dos indicadores de capacidade de suporte de carga – RLM11.	112
4.1.13	Estimativa dos indicadores de capacidade de suporte de carga – RLM12.	113
4.1.14	Estimativa dos indicadores de capacidade de suporte de carga – RLM13.	114
4.2	VALORES ESTIMADOS POR REDES NEURAIAS ARTIFICIAIS (RNA).....	116
4.2.1	Estimativa dos indicadores de capacidade de suporte de carga – RNA1...	116
4.2.2	Estimativa dos indicadores de capacidade de suporte de carga – RNA2...	117
4.2.3	Estimativa dos indicadores de capacidade de suporte de carga – RNA3...	118
4.2.4	Estimativa dos indicadores de capacidade de suporte de carga – RNA4...	119
4.2.5	Estimativa dos indicadores de capacidade de suporte de carga – RNA5...	120
4.2.6	Estimativa dos indicadores de capacidade de suporte de carga – RNA6...	121
4.2.7	Estimativa dos indicadores de capacidade de suporte de carga – RNA7...	122
4.2.8	Estimativa dos indicadores de capacidade de suporte de carga – RNA8...	123
4.2.9	Estimativa dos indicadores de capacidade de suporte de carga – RNA9...	124
4.2.10	Estimativa dos indicadores de capacidade de suporte de carga – RNA10.	125

4.2.11	Estimativa dos indicadores de capacidade de suporte de carga – RNA11	126
4.2.12	Estimativa dos indicadores de capacidade de suporte de carga – RNA12	127
4.2.13	Estimativa dos indicadores de capacidade de suporte de carga – RNA13	128
4.2.14	Estimativa dos indicadores de capacidade de suporte de carga – RNA-FA1	128
4.2.15	Estimativa dos indicadores de capacidade de suporte de carga – RNA-FA2	129
4.2.16	Estimativa dos indicadores de capacidade de suporte de carga – RNA-MA..	130
4.3	VALORES ESTIMADOS POR MÁQUINAS DE VETORES DE SUPORTE (MVS)	131
4.3.1	Estimativa dos indicadores de capacidade de suporte de carga – MVS1..	132
4.3.2	Estimativa dos indicadores de capacidade de suporte de carga – MVS2..	133
4.3.3	Estimativa dos indicadores de capacidade de suporte de carga – MVS3..	134
4.3.4	Estimativa dos indicadores de capacidade de suporte de carga – MVS4..	135
4.3.5	Estimativa dos indicadores de capacidade de suporte de carga – MVS5..	136
4.3.6	Estimativa dos indicadores de capacidade de suporte de carga – MVS6..	137
4.3.7	Estimativa dos indicadores de capacidade de suporte de carga – MVS7..	138
4.3.8	Estimativa dos indicadores de capacidade de suporte de carga – MVS8..	139
4.3.9	Estimativa dos indicadores de capacidade de suporte de carga – MVS9..	140
4.3.10	Estimativa dos indicadores de capacidade de suporte de carga – MVS10	141
4.3.11	Estimativa dos indicadores de capacidade de suporte de carga – MVS11	142
4.3.12	Estimativa dos indicadores de capacidade de suporte de carga – MVS12	143
4.3.13	Estimativa dos indicadores de capacidade de suporte de carga – MVS13	144
4.3.14	Estimativa dos indicadores de capacidade de suporte de carga – MVS-FA1	145
4.3.15	Estimativa dos indicadores de capacidade de suporte de carga – MVS-FA2	145
4.3.16	Estimativa dos indicadores de capacidade de suporte de carga – MVS-MA .	146
4.4	DESEMPENHO DOS MODELOS E METODOLOGIAS AVALIADAS	147
4.4.1	Desempenho dos modelos obtidos por RLM para dados gerais.....	148
4.4.2	Desempenho dos modelos obtidos por RNA para dados gerais.....	150

4.4.3	Desempenho dos modelos obtidos por MVS para dados gerais	152
4.4.4	Comparação das FTPs desenvolvidas pelos modelos	154
5	CONCLUSÃO	161
	REFERÊNCIAS.....	163

1 INTRODUÇÃO

O uso sustentável dos recursos naturais, especialmente do solo e da água, tem-se constituído em tema de crescente relevância, em razão do aumento das atividades antrópicas. Devido a isto, o uso sustentável e a qualidade desses recursos tornou-se uma preocupação crescente, e com isso vêm sendo foco de inúmeras pesquisas. Dentre estas pesquisas, muitas têm sido desenvolvidas a respeito do processo de compressão do solo. Este processo descreve a compactação (expulsão do ar) e a consolidação (expulsão da água) do solo. O entendimento do processo de compressão é essencial para estimar as alterações que podem ocorrer na estrutura do solo, quando submetido à determinada pressão externa.

Richart et al. (2005) citam como indicador de compactação do solo, frequentemente utilizado, a resistência à penetração. Ralisch e Tavares Filho (2002) defendem a penetrometria ou avaliação da resistência do solo à penetração como uma metodologia para estudar a variabilidade estrutural do perfil do solo. De acordo com Lanças (2000), é possível realizar comparações da resistência do solo à penetração, em um mesmo local e em épocas diferentes, desde que o solo esteja nas mesmas condições de teor de água.

Principalmente no Brasil, a resistência do solo à penetração têm sido um dos indicadores de qualidade física do solo para a produção das culturas mais presentes nos artigos científicos depois do intervalo hídrico ótimo, por integrar fatores que afetam diretamente o crescimento das plantas, e com isto a produtividade.

Martins (2012) afirma que associado ao desenvolvimento tecnológico da colheita mecanizada e ao seu potencial em promover compactação do solo, pesquisadores têm utilizado diversas propriedades físicas e mecânicas para quantificar o efeito da compactação sobre a estrutura do solo. Entre essas propriedades citam-se: densidade do solo, porosidade, resistência à penetração, condutividade hidráulica (DIAS JUNIOR et al., 2007; DIAS JUNIOR et al., 2008; LOPES et al., 2006; MARTINS et al., 2002; SILVA et al., 2006) e mais recentemente a pressão de preconsolidação (AJAYI et al., 2009; DIAS JUNIOR et al., 2008). Apesar dessas propriedades serem capazes de identificar a compactação do solo, nenhuma delas, exceto a pressão de preconsolidação, possui a capacidade de

estimar os níveis de pressão que podem ser aplicados aos solos para evitar que a compactação adicional ocorra.

A pressão de preconsolidação (σ_p) é o indicador que expressa a máxima pressão que pode ser aplicada ao solo antes da ocorrência de um incremento na compactação, sendo considerado um valor crítico, já que pressões inferiores podem causar pouca compactação adicional, enquanto estresses maiores provocam considerável compactação adicional, originando a degradação irreversível da estrutura do solo (DAWIDOWSKI et al., 2001).

A pressão de preconsolidação, apesar das dificuldades inerentes à sua obtenção, representa uma medida útil do estado mecânico do solo para o uso, manejo e planejamento de sistemas de mecanização. A estimativa da pressão de preconsolidação, a partir de propriedades do solo facilmente mensuráveis, é, portanto, uma alternativa que pode ser utilizada para contornar as dificuldades.

Neste contexto, o conhecimento destes dois indicadores da compactação do solo, resistência à penetração e tensão de preconsolidação podem ser utilizados para desenvolvimento de estratégias de manejo que minimizem, respectivamente, os riscos de redução de produtividade e de compactação adicional do solo devido aos impactos causados pelas operações, principalmente, motomecanizadas.

Mesmo com a existência de várias metodologias para estimar a capacidade de suporte de carga do solo, incluindo-se métodos empíricos, analíticos e numéricos, pode-se afirmar que os métodos empíricos são de fácil utilização, mas têm como desvantagem a não consideração de alguns parâmetros importantes, e a limitação para certos tipos de materiais. Os métodos analíticos também são de fácil utilização, mas têm como principal desvantagem o fato de serem limitados a materiais com comportamentos semelhantes. No uso dos métodos numéricos deve-se ter acesso a um programa de ensaios que forneçam os parâmetros necessários de modo a que se possam utilizar modelos constitutivos que representem com fidelidade as condições do solo em estudo e muitas vezes, como no caso de análises numéricas tridimensionais, tem-se um custo computacional alto.

Com o intuito de atribuir às máquinas características da inteligência humana de forma a aprender e analisar as relações entre os dados surgiu em 1956 a Inteligência Artificial (IA) que engloba várias técnicas que permitem emular o comportamento humano, dentre as quais se destacam as Redes Neurais Artificiais (RNA), os Algoritmos Genéticos (AGs), os Sistemas Especialistas (SE) e os

Sistemas Baseados em Casos (SBC). A escolha da técnica depende da especificidade do problema.

Além dos sistemas citados acima, as Máquinas de Vetores Suporte (Support Vector Machines - SVMs) constituem uma técnica embasada na Teoria de Aprendizado Estatístico (VAPNIK, 1995) que vem recebendo grande atenção nos últimos anos (HEARST et al., 1998; CRISTIANINI & SHAW-TAYLOR, 2000). Os resultados da aplicação desta técnica se comparam aos obtidos por outros algoritmos de aprendizado, como as Redes Neurais Artificiais (RNA) e, em algumas tarefas, têm se mostrado superiores, tal como na detecção de faces em imagens (HEARST et al., 1998), na categorização de textos (HEARST et al., 1998), em aplicações em Bioinformática (ZIEN et al., 2000).

Diante do que foi exposto, verificou-se a necessidade, junto à perspectiva de se obter resultados positivos, em pesquisar o campo da Inteligência Artificial no âmbito da física do solo que trata da capacidade de suporte de carga. Desta forma levantaram-se algumas hipóteses nas quais se justifica o estudo:

- i. Funções de pedotransferência da capacidade de suporte de carga do solo gerados a partir de modelos de Inteligência Artificial apresentam melhor capacidade preditiva que as funções de pedotransferência utilizadas na atualidade;
- ii. Existe diferença no desempenho preditivo dos diferentes métodos em estudo;
- iii. Modelos preditivos de Inteligência Artificial utilizando número reduzido de variáveis de entrada conseguem expressar resultados com desempenho de estimativa superior ou semelhante às funções de pedotransferência existentes na atualidade.

A partir das considerações apresentadas anteriormente, os objetivos deste trabalho foram desenvolvidos e são apresentados logo a seguir:

1.1 OBJETIVO GERAL

Este trabalho tem por objetivo realizar a comparação entre diferentes metodologias de predição de inteligência artificial e funções de pedotransferência, para a estimativa da capacidade de suporte de carga do solo.

1.2 OBJETIVOS ESPECÍFICOS

- a. Estimar a capacidade de suporte de carga do solo, em função da composição textural, densidade do solo, limites de Atterberg (plasticidade e liquidez), teor de matéria orgânica e do grau de umidade do solo;
- b. Comparar modelos que permitam uma estimativa da pressão de preconsolidação (σ_p) do solo através da utilização de três diferentes técnicas (regressão linear múltipla, redes neurais artificiais e máquinas de vetores de suporte) ao modelo de Dias Junior e Pierce (1995);
- c. Comparar modelos que permitam estimar a resistência à penetração (RP) do solo através da utilização de três diferentes técnicas (regressão linear múltipla, redes neurais artificiais e máquinas de vetores de suporte) ao modelo de Busscher (1990);
- d. Apresentar uma técnica alternativa que permita fornecer valores aproximados de parâmetros físico-mecânicos, que auxiliem no controle da compactação adicional do solo, sem a necessidade de realização de ensaios experimentais.

2 REVISÃO DE LITERATURA

Este capítulo tem a função de identificar o atual estado da arte no que se refere aos aspectos teóricos e práticos relativos à concepção dos indicadores da capacidade de suporte de carga do solo sob a ótica da agricultura, além de seus parâmetros (pressão de preconsolidação e a resistência do solo à penetração) e as formas de determinação diretas e indiretas dos mesmos, através de funções de pedotransferência obtidas por regressão linear múltipla (RLM), redes neurais artificiais (RNA) e máquinas de vetores de suporte (MVS).

2.1 COMPACTAÇÃO DO SOLO

Os problemas de compactação de solo ocorrem quando a capacidade de suporte de carga do mesmo é ultrapassada (MAZURANA, 2011).

A compactação do solo consiste no processo de densificação que ocorre quando uma pressão externa é aplicada sobre o mesmo (SOANE; VAN OUVKERK, 1994). O tráfego de máquinas agrícolas, aliado a condições inadequadas de umidade, é considerado fator determinante para a ocorrência do processo de degradação ocasionado pela compactação (DIAS JUNIOR; PIERCE, 1996; IMHOFF et al., 2001; LIMA et al., 2006; VEIGA et al., 2007). A ausência de revolvimento no sistema de semeadura direta (HÅKANSSON; MEDVEDEV, 1995), o aumento no tamanho e peso das máquinas agrícolas (MOUAZEN et al., 2003) e a utilização equivocada da pressão de inflação dos pneus agrícolas (HÅKANSSON, 2005) também são fatores determinantes na ocorrência da compactação.

O processo de compactação do solo pode gerar a destruição dos agregados com conseqüente reorganização das partículas de argila, silte e areia, resultando em uma estrutura maciça e coesa na matriz do solo (HORN et. al, 1995). De acordo com Tormena et al. (1998) a compactação altera as propriedades físicas do solo, geralmente aumentando a densidade em detrimento da porosidade total, principalmente os poros de maior diâmetro do solo.

O conhecimento do estado de compactação do solo é de fundamental importância para identificar estratégias de prevenção e minimização dos impactos causados pela exploração agrícola e uso do solo, com a finalidade de estabelecer

metodologias para correta quantificação dos impactos causados em áreas agrícolas (GONTIJO et al., 2007).

A compactação do solo promove aumento da densidade do solo e da sua resistência mecânica, além de reduzir a porosidade total alterando a distribuição de poros por tamanho (AJAYI et al., 2009; 2010; HILLEL, 1982), também promove aumento da capacidade de suporte de carga (DIAS JUNIOR et al., 2007, SILVA; DIAS JUNIOR; LEITE, 2007) limitando a absorção de nutrientes, a infiltração e redistribuição de água, a troca gasosa, a emergência das plântulas e o desenvolvimento do sistema radicular o que resulta em decréscimo da produção (ARVIDSSON, 2001; DAUDA e SAMARI, 2002), aumentando a erosão e a potência dos equipamentos usados no preparo do solo (CANILLAS e SALOKHE, 2002).

Frequentemente, algumas propriedades físico-mecânicas relativas ao comportamento compressivo do solo têm sido utilizadas para avaliar a susceptibilidade à compactação. Estas são obtidas da curva de compressão, que é representada graficamente pela relação entre o logaritmo da pressão aplicada e a densidade do solo ou índice de vazios (HOLTZ; KOVACS, 1981). Como exemplos dessas propriedades, citam-se o índice de compressão (I_c), que é um indicativo da suscetibilidade do solo à compactação, e a pressão de preconsolidação (σ_p), que é uma estimativa da capacidade de suporte de carga do solo (DIAS JUNIOR; PIERCE, 1996; KONDO e DIAS JUNIOR, 1999; SILVA et al., 2000; SILVA et al., 2001).

Trabalhos como de Genro Junior et al. (2004) ainda destacam a importância da verificação da resistência à penetração (RP) na identificação de camadas compactadas no solo, visto que esta é apontada como um dos fatores limitantes ao desenvolvimento e estabelecimento das culturas, pois ela expressa o grau de compactação do solo (RICHART et al., 2005).

2.2 CONSOLIDAÇÃO DO SOLO

Em solos saturados, o processo de compactação é também chamado de consolidação. Segundo Reichert et al. (2010), nesse processo, se um solo é submetido a uma pressão, as alterações no volume serão atribuídas, principalmente, à expulsão de água dos espaços do solo. Quando não saturado, a aplicação de uma pressão reduzirá, principalmente, os espaços preenchidos com ar. A água, preenchendo os vazios do solo, e as partículas sólidas do solo são incompressíveis,

portanto, a taxa de consolidação do solo dependerá de sua permeabilidade e compressibilidade.

Os mesmos autores afirmam que a pressão aplicada a uma massa de solo é a “pressão total”, e a subdividem em “pressão neutra”, sendo esta uma parte da pressão total, que durante o processo de consolidação (processo de drenagem) é suportada pela água, e “pressão efetiva”, que é parte da pressão total transferida intergranularmente pelas partículas do solo. Desta forma, durante o processo de consolidação verifica-se um decréscimo gradual da pressão neutra, o que ocasiona um aumento gradual da pressão efetiva.

A consolidação é o processo de transferência gradual de uma pressão aplicada, a partir dos poros preenchidos com água para a estrutura do solo, assim que a água é expulsa para fora dos espaços vazios. A quantidade de água expulsa depende da pressão e da compressibilidade do solo, enquanto a taxa com que esta água é expulsa depende do coeficiente de permeabilidade, da altura, da espessura e compressibilidade do solo (DEPARTMENT OF THE ARMY. U. S, 1970).

2.3 CAPACIDADE DE SUPORTE DE CARGA DO SOLO

No Brasil, tanto na moderna agricultura mecanizada quanto em sistemas que integram a pecuária com a produção agrícola, a grande maioria dos produtores ainda desconhece a capacidade de suporte de cargas dos solos bem como o momento ou a umidade ideal ao tráfego e/ou manejo dos solos agrícolas.

A capacidade de suporte de carga é regida tanto por fatores externos como internos ao solo. Os externos são passíveis de controle sendo, tipo de máquina, tipo de pneu, carga sobre os pneus, pressão de inflação dos pneus, velocidade de deslocamento, pisoteio animal e cobertura vegetal. Já os internos são a textura, agregação, densidade inicial, conteúdo de material orgânico e conteúdo de água (MAZURANA, 2011).

As propriedades físico-mecânicas, que se caracterizam por estimar a capacidade de suporte de carga do solo, mais citadas ao se tratar do comportamento compressivo e da susceptibilidade à compactação do solo são: a coesão e o ângulo de atrito interno, quando se trata do solo como material de construção ou material de suporte (BRAGA, 2014), e o índice de compressão (I_c), a pressão de preconsolidação (σ_p), (DIAS JUNIOR; PIERCE, 1996; KONDO; DIAS

JUNIOR, 1999; SILVA et al., 2000; SILVA et al., 2001) e a resistência a penetração (RP) (GUBIANI, 2014; SANCHEZ, 2012; RICHART et al., 2005), quando a abordagem do tema se dá para solos agrícolas.

Visto que na agricultura a necessidade de avaliar a capacidade de suporte de carga se dá em função de se conhecer a disposição de um solo sofrer compactação, os indicadores mais adequados para essa finalidade seriam a pressão de preconsolidação (σ_p), pois representa a pressão que um solo pode sofrer sem que exista um aporte de compactação e a resistência do solo a penetração (RP) que é um indicador representativo quando se busca as melhores condições para o estabelecimento do sistema radicular das culturas.

2.4 PRESSÃO DE PRECONSOLIDAÇÃO

Dentre as limitações para que o desenvolvimento sustentável seja alcançado na agricultura, uma está relacionada com a resistência mecânica do solo, que ocorre na maioria das vezes devido ao manejo inadequado. Diferentes manejos têm alterado as propriedades físicas do solo (AJAYI et al., 2009; DIAS JUNIOR et al., 2007), causando compactação e restringindo a penetração do sistema radicular devido ser a pressão de turgor insuficiente para vencer a resistência mecânica do solo (GYSI, 2001).

As curvas de compressão obtidas nos ensaios de compressão uniaxial são frequentemente usadas em estudos de compactação do solo (AJAYI et al., 2009, 2010). Essas curvas descrevem a relação entre o logaritmo da pressão aplicada e a densidade do solo ou índice de vazios (CASAGRANDE, 1936; HOLTZ e KOVACS, 1981). A pressão de preconsolidação divide a curva de compressão do solo em uma região de deformações pequenas, elásticas e recuperáveis (curva de compressão secundária) e a região de deformações plásticas e não recuperáveis (curva de compressão virgem) (HOLTZ e KOVACS, 1981). Assim, a pressão de preconsolidação é um indicador da máxima pressão já aplicada ao solo (DIAS JUNIOR e PIERCE, 1995; HOLTZ e KOVACS, 1981) e também um indicador da resistência do solo (ARVIDSSON, 2001), sendo usada para determinação da capacidade de suporte de carga dos solos, podendo variar de valores próximos a zero para solos que não receberam cargas a valores tão elevados quantos forem as cargas das máquinas e implementos agrícolas que por determinado solo trafeguem.

Defossez e Richard (2002), Rücknagel et al., (2007) definem a pressão de preconsolidação como um indicador útil da resistência intrínseca do solo e de sua capacidade de suporte de carga em dada umidade. Desta forma, na agricultura deve-se evitar a aplicação de pressões maiores do que a pressão de preconsolidação para evitar que a compactação ocorra (DEFOSSEZ; RICHARD, 2002).

A pressão de preconsolidação depende de vários fatores como: variação da pressão devido à erosão e escavações, ciclos de secagem e umedecimento, textura, estrutura e densidade do solo, manejo do solo, matéria orgânica, mineralogia, entre outros (DIAS JUNIOR e PIERCE, 1995; McBRIDE e JOOSSE, 1996).

2.5 RESISTÊNCIA DO SOLO À PENETRAÇÃO

A resistência do solo à penetração (*RP*) integra os efeitos da densidade e da umidade nas condições físicas do solo necessárias para o crescimento das raízes (TORMENA et al., 2002).

Sendo a resistência mecânica do solo à penetração apontada como um dos fatores limitantes ao desenvolvimento e estabelecimento das culturas, pois ela expressa o grau de compactação do solo (RICHART et al., 2005), pode-se dizer que a resistência do solo à penetração é uma das propriedades físicas do solo diretamente relacionados com o crescimento das plantas (LETEY, 1985) e modificada pelos sistemas de preparo do solo.

De acordo com Cunha et al. (2002) a resistência do solo à penetração (*RP*) tem sido utilizada, com inúmeras aplicações em diversas áreas da pesquisa agrônoma, sendo várias já consolidadas, tais como: detecção de camadas compactadas, em estudo da ação de ferramentas de máquinas no solo, prevenção de impedimento mecânico ao desenvolvimento do sistema radicular das plantas, predição da força de tração necessária para execução de trabalhos e para conhecimento de processos de umedecimento e de ressecamento.

Valores excessivos de resistência do solo à penetração podem influenciar o crescimento das raízes em comprimento e diâmetro (MEROTTO e MUNDSTOCK, 1999) e na direção preferencial do crescimento radicular (IIJIMA e KONO, 1991). Além disso, estudos recentes indicam que a resistência do solo à penetração das raízes tem efeitos diretos no crescimento da parte aérea das plantas (MASLE e

PASSIOURA, 1987) e na partição de carboidratos entre a raiz e parte aérea (MASLE e FARQUHAR, 1988).

Tratando-se da influência da RP sobre as culturas, Canarache (1990) sugere que valores acima de 2,5 MPa começam a restringir o pleno crescimento das raízes da maioria das plantas. Segundo Beutler et al. (2006), valores de 2,0 a 3,0 MPa são limitantes à produtividade de soja, enquanto Merotto e Mundstock (1999) indicam que a resistência do solo à penetração (RP) maior que 3,5 MPa causa severa limitação ao crescimento de plantas de trigo. Segundo Rosolem et al. (1999), a RP da ordem de 1,3 MPa reduz à metade o crescimento das raízes seminais adventícias do milho. Torres e Saraiva (1999), em experimentos com soja em latossolo roxo, observaram valores de resistência em torno de 3,5 a 6,5 MPa (solo na consistência friável) como causadores de possíveis problemas de impedimento mecânico.

Carvalho et al. (2008) afirma que ao analisar dados de atributos de solo mediante os métodos estatísticos clássicos são ignoradas as consequências da heterogeneidade espacial sobre a representatividade dos valores médios de amostras, e ressalta que métodos geoestatísticos (análise de semivariogramas e krigagem) estão sendo utilizados para analisar tanto a dependência espacial como para interpolar atributos de solo através da krigagem (TRANGMAR et al., 1985; SOUZA et al., 2001; SOUZA et al., 2004). No entanto, pouco se tem feito utilizando-se modelos de mineração de dados ou sistemas de inteligência artificial na busca de estimar a resistência do solo à penetração.

2.6 MÉTODOS PARA OBTENÇÃO DA CAPACIDADE DE SUPORTE DE CARGA DO SOLO

Nota-se que a capacidade de suporte de carga do solo reflete um importante atributo físico da qualidade do solo e seus indicadores são peças-chave para a conservação do solo. Em sistemas agrícolas estes indicadores podem ser utilizados para definir o momento adequado para a entrada de máquinas ou animais na área, de modo a evitar compactação adicional e consequente degradação da estrutura do solo.

Tanto a pressão de preconsolidação quanto a resistência a penetração podem ser obtidas de forma direta em laboratório. Já a condição de obtenção direta

a campo se dá apenas para a resistência à penetração, visto que o consolidômetro, equipamento utilizado para obtenção da pressão de preconsolidação, é um equipamento pneumático de uso laboratorial.

Uma forma alternativa para a obtenção de propriedades físicas do solo é a partir de métodos indiretos, que consiste em prever determinados indicadores a partir de propriedades de solo disponíveis, como a textura e estrutura, entre outras (SOARES, 2013; BOUMA E LANEN, 1987). Estes métodos indiretos são denominados Funções de Pedotransferência, e consistem em estimar parâmetros ou índices do solo através de métodos estatísticos, lógicos, inteligência artificial entre outros.

2.6.1 Métodos diretos

De maneira geral os métodos diretos para obtenção de propriedades físicas do solo, apesar de mais trabalhosos e de necessitarem de maior qualificação de mão-de-obra para sua execução, são considerados mais confiáveis que os métodos indiretos, visto que estes visam sempre estimar os resultados obtidos pelos métodos diretos.

2.6.1.1 Métodos diretos de obtenção da resistência do solo à penetração

A avaliação da resistência do solo à penetração de forma direta é realizada com a utilização de penetrógrafos ou penetrômetros automáticos, de anel dinamométrico ou de impacto, sendo que, de acordo com Reichert (2010), estes são equipamentos de técnica simples e de fácil utilização, desde que sejam tomados os devidos cuidados na interpretação dos resultados, em virtude da influência de fatores como conteúdo de água, densidade e textura do solo, nos valores de resistência. Com esses cuidados aplicados, podem ser obtidos resultados muito úteis para a tomada de decisão quanto à compactação em níveis prejudiciais às plantas.

O penetrógrafo é um equipamento que mede a resistência da camada superficial do solo até 80 cm de profundidade. Está equipado com plotter, ou digitalizado, o que continuamente cadastra as resistências nas camadas penetradas. É usado na agricultura para medir a resistência do solo a ser penetrado por raízes,

sendo que os mais modernos possuem sistema digital georreferenciado (REICHERT, 2010).

O penetrômetro é usado pelos mesmos motivos que o penetrógrafo e trabalha na mesma faixa de profundidade. Equipado com um manômetro para facilitar a leitura, o penetrômetro é um instrumento automatizado para qualificar e quantificar os reais efeitos da compactação do solo. O equipamento é para uso em agricultura de precisão e conservacionista, em laboratório ou no campo. Possibilita a obtenção de medidas estáticas e a transferência de dados de resistência à penetração para a geração de mapas, em computador.

Trabalhos têm sido realizados comparando os diferentes aparelhos (ROQUE et al., 2003; BEUTLER et al., 2007; MOLIN et al., 2012; LIMA et al., 2013). Alguns comparando o penetrômetro de anel dinamométrico (resistência estática) com o de impacto (resistência dinâmica), em meios menos compressíveis de pouca elasticidade (solos arenosos), a força estática e a força dinâmica são semelhantes, enquanto nos meios sujeitos a compressões elásticas (solos argilosos), a resistência dinâmica deve ser maior que a estática, e a diferença percentual aumentar com a resistência do meio.

Apesar da facilidade de utilização, ambos os equipamentos são considerados de alto custo de aquisição, tornando-se onerosos tanto para os produtores quanto para experimentos científicos de pequeno porte (COLLARES et al., 2004).

2.6.1.2 Métodos diretos de obtenção da pressão de preconsolidação

A obtenção de σ_p de forma direta se dá a partir de um método denominado ensaio de consolidação, que, de acordo com a publicação EM 1110-2-1906 (DEPARTMENT OF THE ARMY. U. S, 1970), consiste no processo de transferência gradual de uma carga aplicada ao solo até que todos os vazios deste sejam comprimidos. A quantidade de água que sai da amostra depende da intensidade da carga e da compressibilidade do solo, enquanto a taxa com que a água é drenada depende do coeficiente de permeabilidade, da densidade do solo e também da compressibilidade da amostra (DEPARTMENT OF THE ARMY. U. S, 1970).

Todavia, para realização de um ensaio de consolidação faz-se necessário o uso de um equipamento específico, denominado consolidômetro. Esse equipamento não é produzido no Brasil, e os modelos disponíveis no exterior, automatizados ou

não, são caros, o que dificulta a sua utilização.

A pressão de preconsolidação também pode ser obtida em laboratório por meio do ensaio de compressão uniaxial, o qual requer aparelhos sofisticados para a sua realização. Além do tempo gasto na realização do ensaio, há necessidade de usar um método gráfico ou de planilhas para a sua determinação (PARENTE e MAIA, 2011).

2.6.2 Métodos indiretos

Métodos indiretos são aqueles que não fornecem diretamente a propriedade ou índice que se deseja quantificar, sendo que para estimá-lo, é necessário se utilizar de interação entre outras propriedades ou índices conhecidos ou de mais fácil obtenção, e fatores e/ ou coeficientes a serem determinados para cada situação e para cada método indireto.

2.6.2.1 Métodos indiretos de obtenção da resistência à penetração

Pelo fato da resistência à penetração (RP) ser função de algumas propriedades do solo já mencionadas, modelos matemáticos têm sido elaborados no intuito de incluir o efeito desses parâmetros na resistência à penetração (REICHERT, 2010).

O modelo não-linear desenvolvido por Busscher (BUSSCHER, 1990) (Equação 1) é utilizado por muitos autores (BLAINSKI et al. 2008; FREDDI, 2007; GUBIANI, 2012; LIMA et al. 2006-2007; SUZUKI et al. 2008, KLEIN & CAMARA, 2007), e considera que a resistência à penetração é variável com a umidade e densidade do solo, sendo amplamente utilizado para estudos de compactação e qualidade de solo.

$$RP = a\theta^b D_s^c \quad (1)$$

onde: RP = resistência à penetração (Mpa); θ = conteúdo volumétrico de água ($m^3.m^{-3}$); D_s = densidade do solo ($kg.m^{-3}$); a , b e c são parâmetros empíricos de ajuste do modelo.

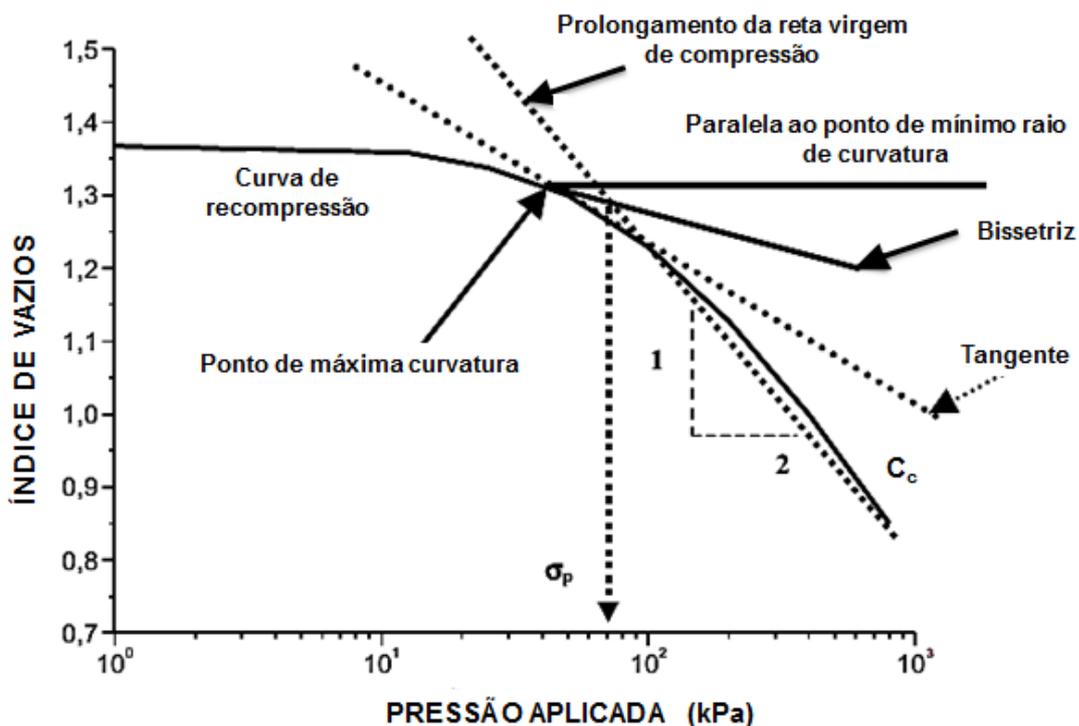
Outros modelos são apresentados na literatura, embora mais restritivos, devido ao menor número de parâmetros incluídos.

2.6.2.2 Métodos indiretos de obtenção da pressão de preconsolidação

Vários métodos para estimar a pressão de preconsolidação estão disponíveis na literatura (CASAGRANDE, 1936; DIAS JUNIOR e PIERCE, 1995; McBRIDE e JOOSSE, 1996) sendo utilizados frequentemente nas ciências agrárias.

O método gráfico proposto por Casagrande (1936) (Figura 1) consiste no ponto de raio mínimo ou de máxima curvatura da curva de compressão do solo. Todavia, a literatura relata que à medida que as perturbações nas amostras indeformadas aumentam, ou o conteúdo de água do solo é alto, torna-se difícil identificar o ponto de máxima curvatura pelo fato de que as curvas de compressão do solo tendem a linearidade, o que pode constituir em restrição para a escolha do ponto de raio mínimo ou de máxima curvatura da curva de compressão do solo (SILVA et al., 2010).

Figura 1 - Esquema ilustrativo da determinação da pressão de preconsolidação obtido da curva de compressão pelo método de Casagrande



Já o método proposto por Dias Junior e Pierce (1995), estima a pressão de preconsolidação utilizando uma planilha eletrônica. Esse procedimento, de acordo com Silva (2010), fornece uma estimativa rápida e confiável da pressão de preconsolidação, pois elimina a subjetividade associada ao procedimento gráfico.

Outra forma de estimar a σ_p do solo é com a utilização de modelos de descrição da curva de compressão. A curva de compressão do solo, que representa graficamente a relação entre o índice de vazios (ε) ou densidade do solo (D_s) e o logaritmo (base 10) da pressão aplicada (kPa). Entretanto, existem vários modelos (Tabela 1), dentre eles variações do modelo de van Genuchten (1980), Friton (2001) e Assouline (2002), e ainda o modelo de Gompertz (1825), adaptado por Gregory et al. (2006) para descrever a curva de compressão.

Tabela 1 - Modelos utilizados para descrever resultados obtidos nos ensaios de compressão uniaxial

Modelo	Denominação
$\varepsilon = \varepsilon_{1600} + (\varepsilon_i - \varepsilon_{1600})[1 + (a\sigma)^b]^{-c}$	vG1
$\varepsilon = \varepsilon_f + (\varepsilon_i - \varepsilon_f)[1 + (a\sigma)^b]^{-c}$	vG2
$\varepsilon = \varepsilon_{1600} + (\varepsilon_i - \varepsilon_{1600})[1 + (a\sigma)^b]^{-[1 - (\frac{1}{b})]}$	vG3
$\varepsilon = \varepsilon_f + (\varepsilon_i - \varepsilon_f)[1 + (a\sigma)^b]^{-[1 - (\frac{1}{b})]}$	vG4
$\varepsilon = (\varepsilon_i)[1 + (a\sigma)^b]^{-c}$	vG5
$\varepsilon = (\varepsilon_i)[1 + (a\sigma)^b]^{-[1 - (\frac{1}{b})]}$	vG6
$\varepsilon = (\varepsilon_i)[1 + (a\sigma)^b]^{-[1 - (\frac{1}{b})]}$	vG7
$\rho = \rho_p - (\rho_p - \rho_0)[1 + (a\sigma)^b]^{-c}$	Frit
$\rho = \rho_0 + (\rho_{max} - \rho_0) \left[1 - e^{-(a\sigma)^b} \right]^{-c}$	Ass
$\varepsilon = a + c \exp[-\exp(b(\text{Log}_{10}\sigma - m))]^{-1}$	Gomp

Fonte: (GREGORY et al., 2006)

σ = carga aplicada (kPa); ε = índice de vazios; ε_i = índice de vazios inicial (para $\sigma=0$); ε_f = índice de vazios na última carga do teste; ρ = densidade final do solo (g cm^{-3}); ρ_0 é a densidade inicial do solo (para $\sigma=0$), ρ_p é a densidade de partículas do solo, ρ_{max} , a, b, c e m são coeficientes de ajuste dos modelos.

Entretanto, há ainda uma carência de estudos usando modelos de capacidade de suporte de carga e pressão de preconsolidação através da mineração de dados ou sistemas de inteligência artificial.

2.6.2.3 Funções de pedotransferência

Segundo Budiman et. al (2003), as interpretações de levantamentos de solos são pedotransferências para estimar, a partir de dados existentes, outras características ou propriedades correlacionadas ao solo. Quando a pedotransferência é expressa de forma quantitativa, por meio de equações matemáticas, ela é designada por Funções de Pedotransferência (Pedotransfer Functions – PTF).

Bouma e Lanen (1987) denominaram as equações de regressão estatística que expressam relações entre propriedades do solo, de “funções de transferência” e mais tarde “funções de pedotransferência” (BOUMA, 1989). Este termo foi introduzido para padronizar outros termos anteriormente utilizados com a mesma finalidade (McBRATNEY et al., 2002). Assim, as funções de pedotransferência (FPTs) foram definidas como a estimativa de certas propriedades do solo, de obtenção mais laboriosas e/ou mais cara, a partir de propriedades mais baratas, facilmente medidas, ou ainda disponíveis em relatórios de levantamentos de solos ou em Sistemas de Informação Geográfica (SIGs) (BOUMA, 1989; McBRATNEY et al., 2002; SAXTON et al. 1986; MENG et al. 1987; RAWLS et al. 1991; KERN 1995; TOMASELLA et al., 2000). Deste modo, funções de pedotransferência são equações de regressão ou modelos que relacionam propriedades básicas do solo entre si, e que são de importância para produção agrícola, e manejo de recursos naturais (SALCHOW et al., 1996). Segundo Wagenet et al. (1991), citado por Tietje e Hennings (1996), o princípio das FPTs consiste em que o sistema de informação ou os dados de solo permitam expressar, de forma matemática, funções de pedotransferência específicas para uma variedade de propriedades e qualidades de solo.

Contudo, Minasny et al. (2003) alertam para a necessidade de se definir dois princípios básicos de FPTs, evitando assim, o mau uso do conceito pedotransferência: (i) eficiência; (ii) incerteza. O primeiro princípio se refere a não prognosticar algo que é mais fácil e mais barato medir ou determinar. Como o objetivo de funções de pedotransferência é prever propriedades cujas medidas ou determinações diretas são difíceis, laboriosas ou muito caras, os preditores devem ser de obtenção mais fácil ou mais barata. O custo e o esforço para obter a informação sobre o preditor deverá ser menor do que o de obter a informação sobre

o que se pretende prever. O segundo princípio se refere a não usar FPTs, a menos que se possa avaliar a incerteza associada e, para um determinado problema, se um conjunto de FPTs alternativas está disponível, usar aquela com menor variância.

Uma FPT tende a ser tão mais precisa quanto mais homogêneo forem os solos que compõem a base de dados e, quão mais próximos destes estiverem os que terão seus dados estimados (OLIVEIRA et al., 2002).

Várias têm sido as propostas, de metodologias indiretas, para obtenção da capacidade de suporte de carga do solo. Trabalhos no sentido de relacionar propriedades físicas e mecânicas do solo a fim de desenvolver funções de pedotransferência vêm sendo realizados tanto no Brasil (IMHOFF et al., 2004; DIAS JÚNIOR et al., 2004; LIMA et al., 2006) como no exterior (ALEXANDROU e EARL, 1998; CANARACHE et al., 2000; MOSADDEGHI et al., 2003; HORN e FLEIGE, 2003), principalmente obtidas através de Regressão Linear Múltipla (RLM), mas ainda há necessidade de informações para o desenvolvimento de melhores funções, sendo as Redes Neurais Artificiais (RNA) e as Máquinas de Vetores de Suporte (MVS) vistas como possibilidades para tal.

Contudo a utilização destas técnicas baseia-se no aprendizado de máquinas (AM), cujo objetivo é o desenvolvimento de técnicas computacionais sobre o aprendizado bem como a construção de sistemas capazes de adquirir conhecimento de forma automática.

2.6.2.4 Aprendizado de Máquina (AM)

O aprendizado de máquina é uma subdivisão da inteligência artificial (IA) dedicada à criação e aperfeiçoamento de algoritmos e técnicas que permitam ao computador aprender (AMORIN et al., 2008), ou seja, é um programa de computador que toma decisões baseado em experiências acumuladas através da solução bem sucedida de problemas anteriores. O AM tem grande utilidade quando se tem problemas que não são facilmente programáveis usando equações matemáticas e regras determinísticas. As redes neurais artificiais – RNA e as MVS apresentam equações matemáticas genéricas, ou seja, apresentam funções que não são programadas especificamente para um único problema.

As RNA e as MVS apresentam não apenas formulações matemáticas, mas também um conjunto de coeficientes e pesos que são ajustados por meio de um

processo de treinamento; isto é, realizam o aprendizado a partir de exemplos, visando a diminuição do erro associado ao treinamento, atuando inclusive em processos não-lineares, diferente do que acontece com as RLM.

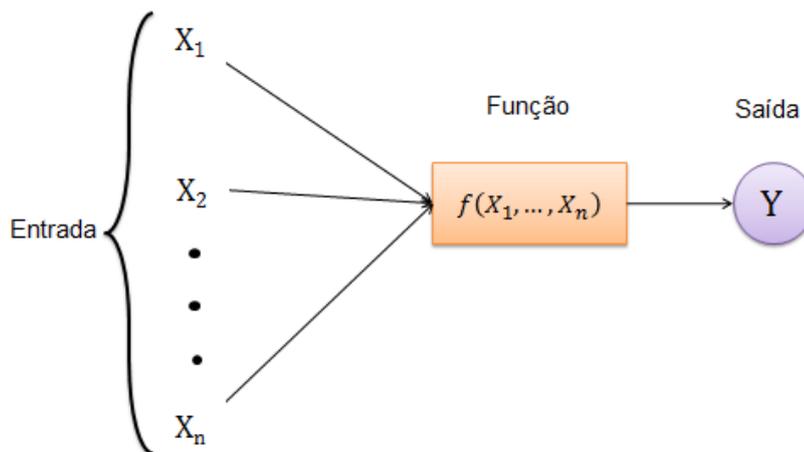
O aprendizado, seja supervisionado ou não, é guiado pelas amostras de treinamento que disponibilizamos a esses sistemas. Assim, para todos os sistemas que codificam o aprendizado de máquina, as seguintes variáveis são definidas:

- Amostras de entrada x , geralmente devem ser na forma vetorial. Essas amostras são geradas independente e identicamente distribuídas segundo uma função distribuição de probabilidade desconhecida $P(x)$. $x \in \mathbb{R}^n$;
- Identificação da amostra por y é a classe à qual x pertence;
- $f(x)$ é a função que realiza o mapeamento do domínio das entradas para o domínio das saídas; o conjunto de funções $f(x)$ também é chamado de hipóteses;
- As amostras x são identificadas por um índice t ; quando duas amostras x estão sendo referenciadas, usa-se os índices i e j , ou seja, $i, j \in t = 1, 2, \dots, N$.

2.6.2.4.1 Regressão Linear Múltipla (RLM)

A regressão linear múltipla, técnica introduzida por Stenberg et al. (1960), se faz apropriada quando o problema de pesquisa envolve uma única variável dependente relacionada a duas ou mais variáveis independentes (Figura 2).

Figura 2 - Representação do relacionamento entre variáveis de um processo



Fonte: Autor.

Braga (2014) afirma que a análise de regressão múltipla tem com objetivo

prever as mudanças na variável dependente como resposta a mudanças nas variáveis independentes, sendo esse objetivo alcançado por meio da técnica dos mínimos quadrados, além desta poder prever a magnitude ou grau de influência da de cada variável independente sobre a dependente.

A regressão linear múltipla (Multiple Linear Regression–MLR) busca estabelecer uma relação linear entre as variáveis preditoras e preditas aplicando o método dos mínimos quadrados. Para isso, faz uso tanto na calibração clássica como na calibração inversa. O modelo RLM pode ser obtido a partir de uma matriz X de respostas instrumentais com dimensão $(m \times k)$, onde m representa o número de amostras e k o número de variáveis (no caso de espectros $k =$ comprimentos de onda). Além disso, utiliza os dados de um vetor y de dimensão $(m \times 1)$ que contém as concentrações (ou outra propriedade) obtidas por um método de referência das amostras (NUNES, 2008).

Dentre os métodos propostos com a finalidade de selecionar comprimentos de onda de um espectro que resulte em modelos de calibração multivariada com precisão elevada o mais utilizado, no contexto de geração de FPTs é o método de regressão *stepwise* (SOARES, 2013).

O método de regressão *stepwise* é um procedimento padrão para seleção de variáveis que combina dois outros métodos, o *forward selection* e *backward elimination* (MONTGOMERY et al. apud CHONG e JUN, 2005). O algoritmo, progressivamente, adiciona novas variáveis ao modelo, iniciando daquela com maior correlação com a resposta, como no método *forward selection* e incorpora um mecanismo de eliminação de variáveis igual ao método de *backward elimination*. O *forward selection* é um método iterativo que começa com uma variável (x) e, progressivamente, adiciona mais variáveis ao modelo de regressão até que um critério de parada seja satisfeito. A variável inicial deve apresentar máxima correlação com a variável de resposta (y). A cada iteração, é construído um novo modelo e o efeito da variável incluída é avaliado por um teste- F . A variável com um valor de F maior que um F -crítico é incluída no modelo. Já o método *backward elimination*, inicia-se com a construção de um modelo de regressão que utiliza todas as variáveis disponíveis e, subsequentemente, variáveis são retiradas e o efeito dessa eliminação é avaliado, da mesma forma que no método *forward selection*. As variáveis com valores de F menores que F -crítico são descartadas do modelo (NUNES, 2008).

De acordo com Diniz (2008), o procedimento básico do modelo *stepwise* é composto por 4 etapas:

1. seleciona-se entre as variáveis preditoras x a mais correlacionada com a variável dependente y (suponha x_1) e encontra-se a equação de regressão linear de primeira ordem $\hat{y} = f(x_1)$;

2. avalia-se a significância de x_1 . Caso não seja significativa, ela é descartada e adota-se um modelo $y = y_{\text{médio}}$ como o melhor. Se for significativa, pesquisa-se a segunda variável preditora a entrar na equação. Isso é feito analisando-se o coeficiente de correlação parcial de todas as variáveis x que ainda não entraram na equação com y . A variável com o maior coeficiente de correlação parcial com y é selecionada (suponha x_2), e a segunda equação de regressão é ajustada;

3. a regressão global é checada pela significância, a melhoria no valor de R^2 é registrada, e o F -valor parcial para as variáveis x_1 e x_2 é examinado. O menor dos dois valores de F parcial é então comparado com um ponto percentual F apropriado, e a correspondente variável preditora é retida ou rejeitada na equação de acordo com a significância do teste. Um preditor que pode ter sido o melhor candidato a entrar na equação em um estágio anterior pode, num estágio posterior, ser considerado supérfluo devido às relações entre ele e outras variáveis contidas na equação de regressão;

4. o procedimento é encerrado quando não existirem mais variáveis a serem removidas da equação e quando a próxima melhor variável não for aceita na equação. Como é testada a entrada de cada variável na equação, conseqüentemente obtém-se uma série de avaliações do efeito R^2 (coeficiente de correlação múltipla).

2.6.2.4.2 Redes Neurais Artificiais (RNA)

As Redes Neurais Artificiais (RNA) são agrupamentos de unidades de processamento (neurônios ou nós), estruturadas e interconectadas, cujo funcionamento é análogo a uma estrutura neural de organismo inteligente (MULLER e FILL, 2003). As RNA extraem seu poder computacional da sua distribuição de estrutura maciçamente paralela e da sua habilidade de aprender/generalizar, tornando possível a resolução de problemas complexos nas mais diferentes áreas do conhecimento (HAYKIN, 2001).

As redes neurais artificiais (RNA) são sistemas paralelos distribuídos, compostos de unidades simples de processamento, que calculam determinadas funções matemáticas. Tais unidades são dispostas em uma ou mais camadas e interligadas por um grande número de conexões. Na maioria dos modelos, essas conexões estão associadas a pesos os quais, após o processo de aprendizagem, armazenam o conhecimento adquirido pela rede. O funcionamento dessas redes é inspirado em uma estrutura biológica concebida pela natureza: o cérebro humano (BRAGA et al., 2000; HAYKIN, 2001; KOVÁCS, 2002).

Uma RNA se assemelha ao cérebro, pois: (i) o conhecimento é adquirido através de um processo de aprendizagem e (ii) são utilizadas forças de conexão entre os neurônios, conhecidas como pesos sinápticos, para armazenar o conhecimento adquirido (HAYKIN, 2001). Os neurônios artificiais são interligados segundo uma dada configuração tendo cada ligação um peso ($w_{i,j}$) que representa a força do sinal enviado.

Segundo Valença (2005) o aprendizado ou treinamento em RNA está associada à capacidade de dar respostas coerentes para dados não apresentados a ela previamente durante o treinamento. O processamento da informação em modelos baseados em redes neurais artificiais (RNA) é feito por meio estruturas neurais artificiais em que o armazenamento e o processamento da informação são realizados de maneiras paralela e distribuída por elementos processadores relativamente simples denominado neurônios.

As RNA têm sido utilizadas com sucesso para modelar relações envolvendo séries temporais complexas em várias áreas do conhecimento. Segundo Galvão et al. (1999), em função de sua estrutura não-linear as redes conseguem captar características mais complexas dos dados, o que nem sempre é possível com a utilização das técnicas estatísticas tradicionais.

Soares (2013) gerou funções de pedotransferência para retenção de água no solo, das quais as geradas por redes neurais artificiais apresentaram capacidade preditiva superiores a análise de regressão linear múltipla, nas diferentes classes texturas e potenciais matriciais estudados.

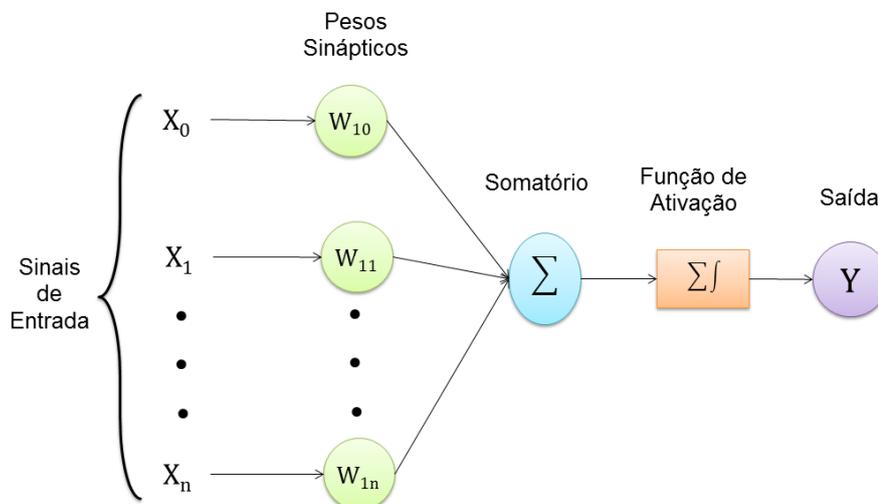
O trabalho desenvolvido por Braga (2014) teve como objetivo avaliar um modelo de estimativa da resistência do solo ao cisalhamento utilizando redes neurais artificiais para a obtenção dos parâmetros de resistência (coesão e ângulo de atrito interno) em função da composição textural, densidade do solo, limites de

Atterberg (plasticidade, liquidez e índice de plasticidade) e do grau de umidade do solo. O autor também aponta que as redes neurais artificiais foram aplicadas extensivamente para muitas tarefas de predição, uma vez que têm a capacidade de modelar a relação não linear entre um conjunto de variáveis de entrada e as saídas correspondentes.

2.6.2.4.2.1 O neurônio Artificial

O modelo matemático de um neurônio artificial foi primeiramente idealizado pelos pesquisadores W. S. McCulloch e W. H. Pitts no ano de 1943 (McCULLOCH e PITTS, 1943). Compõe -se basicamente de conexões emulando os dendritos, pesos emulando as sinapses, uma função de mapeamento emulando o corpo celular, e uma saída emulando o axônio (Figura 3).

Figura 3 - Modelo matemático de neurônio artificial



Fonte: Autor (Adaptado de Ferraz, 2013).

De acordo com Ferraz (2013) cada neurônio é constituído pelos seguintes elementos:

- Sinapses ou pesos sinápticos: formam o conjunto de elos de conexão, caracterizada por um peso. Especificamente, a função do peso é ponderar o sinal de entrada da sinapse conectada ao neurônio. As redes neurais artificiais podem

apresentar também pesos adicionais, denominados de bias, que tem a função de evitar a geração de erros quando todos os dados de entradas são nulos.

- Somatório: agrega os dados das entradas ponderados pelos respectivos pesos;
- Função de ativação: é uma função de ordem interna, sendo uma decisão tomada pelo próprio neurônio sobre o que fazer com o valor resultante do somatório das entradas ponderadas.
- Função de Transferência: é uma função de saída ou limiar lógico. Ela controla a intensidade de ativação para se obter o desempenho desejado na rede.

2.6.2.4.2.2 Função de ativação

Em uma RNA, cada unidade de processamento está associado a um estado de ativação que é determinado pela função de ativação, contínuo ou discreto, que se quer representar com o modelo. A função escolhida para o estado de ativação é responsável pelo sinal a ser transmitido por um determinado neurônio aos demais a ele conectados. (VALENÇA, 2010).

Haykin (2001) afirma que as funções mais utilizadas são: linear, degrau, sigmoide logística e tangente hiperbólica. Na Tabela 2, estão dispostas as funções e suas representações gráficas.

Silva et al (2004) descreve as funções de ativação da seguinte forma:

- Função linear: é a função que não limita a saída da RNA e é usada para armazenar entrada e saída de dados. Os neurônios que possuem esta função atuam como aproximadores lineares;
- Função degrau: é a função utilizada para neurônios que tomam decisões binárias, limitado a saída do neurônio somente a dois valores, sendo assim, classificadora;
- Função sigmoide logística: é uma função limitada que assume valores entre um limite superior e um inferior (0 e 1), sem jamais atingi-los;
- Função tangente hiperbólica: é uma função limitada, definida no intervalo de -1 e +1.

Tabela 2 - Funções de ativação e suas representações gráficas.

Função	Equação	Representação gráfica
Linear	$f(n) = n$	
Degrau	$f(n) = \begin{cases} 1, \forall n \geq 0 \\ 0, \forall n < 0 \end{cases}$	
Sigmoide Logística	$f(n) = \frac{1}{1 + e^{-n}}$	
Tangente Hiperbólica	$f(n) = \frac{e^n - e^{-n}}{e^n + e^{-n}}$	

Fonte: (FERRAZ, 2013).

As funções tangentes hiperbólica e sigmoide são as mais utilizadas em redes neurais artificiais, pois apresentam diversas características favoráveis, como o fato de serem funções semi-lineares, contínuas, simétricas, deriváveis em toda sua extensão, crescente e limitadas por assíntotas horizontais (REINKE, 2008).

2.6.2.4.2.3 Arquitetura da rede neural artificial

A arquitetura refere-se à maneira como os neurônios da rede estão organizados. Existem várias estruturas que diferem umas das outras em função do número de camadas e pela forma como seus neurônios interagem (FERRAZ, 2013).

Oliveira (2005) ressalta que definir a arquitetura de uma RNA é muito importante devido ao fato de que seu arranjo depende do problema a ser tratado pela rede. Ademais, a arquitetura da rede está intimamente relacionada ao algoritmo de aprendizagem usado para treinamento. Na escolha da estrutura a ser utilizada são analisados: número de camadas, número de nós, tipo de conexões entre os nós e a topologia da rede.

Braga (2000) afirma que a arquitetura de uma rede é definida pelos seguintes

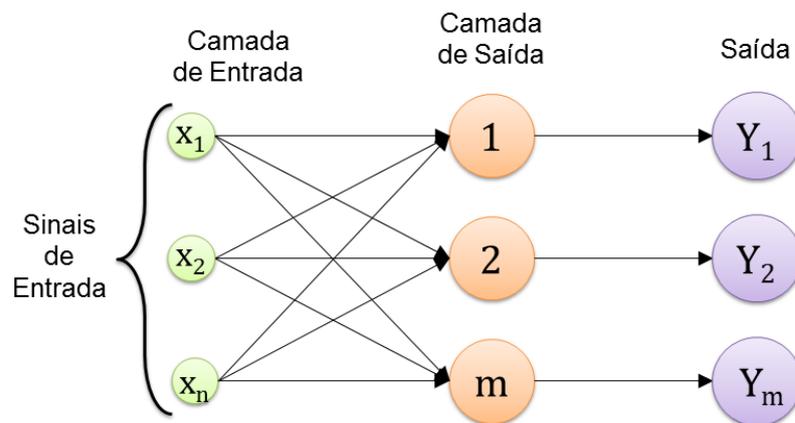
parâmetros: número de camadas da rede, número de neurônios em cada camada, tipo de conexão entre os neurônios e topologia da rede.

2.6.2.4.2.3.1 Redes Feedforward (Única Camada)

São redes neurais constituídas por apenas um agrupamento de neurônios que recebem informação simultaneamente. Este agrupamento recebe o nome de camada.

Esse tipo de rede também é acíclica, ou seja, não possui laços de realimentação. Como pode ser observado na Figura 4, há uma camada de nós de fonte que recebem sinais de excitação do meio externo e estes se conectam com a camada de neurônios, que por sua vez, ligam-se aos nós de saída da rede (HAYKIN, 2001).

Figura 4 - Representação de rede neural única camada



Fonte: Autor. (Adaptado de Soares, 2013).

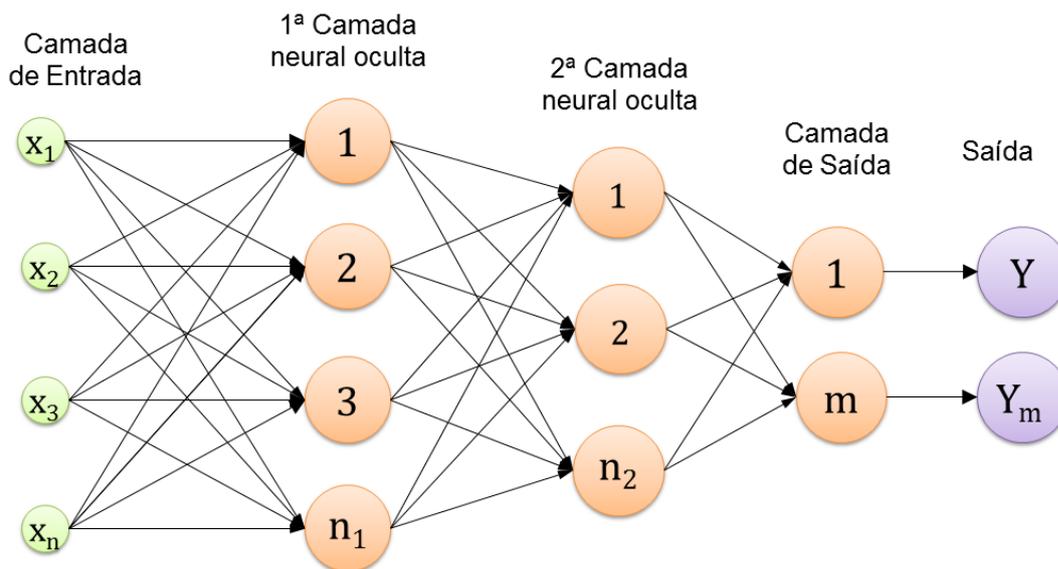
Esse tipo de rede é utilizado em telecomunicações, onde modems de alta velocidade de transmissão utilizam equalizadores adaptativos de linha e canceladores adaptativos de eco. Cada um desses sistemas adaptativos utiliza uma rede neural (WIDROW et al., 1994).

2.6.2.4.2.3.2 Redes Feedforward (Multicamadas)

Este tipo de rede se distingue da anterior pela presença de uma ou mais camadas escondidas de neurônios (FERRAZ, 2013), visto também possuem fluxo de informação unidirecional, porém, neste caso, há presença de camadas ocultas, cujos nós computacionais são chamados de neurônios ocultos. Devido ao conjunto extra de conexões sinápticas e da riqueza de interações neurais, as camadas ocultas são capazes de extrair características complexas do ambiente em que atuam (HAYKIN, 2001).

Nas redes de múltiplas camadas, como a mostrada na Figura 5, cada camada tem uma função específica (OLIVEIRA, 2005). A camada de saída final recebe os estímulos da camada intermediária e constrói a resposta global para o padrão de ativação fornecido pelos nós de fonte da camada de entrada. As camadas intermediárias funcionam como extratoras de características, codificando através de seus pesos as características apresentadas nos padrões de entrada, fazendo com que a rede crie uma representação própria do problema, com mais riqueza e complexidade (REZENDE, 2003).

Figura 5 - Representação de rede neural com múltiplas camadas

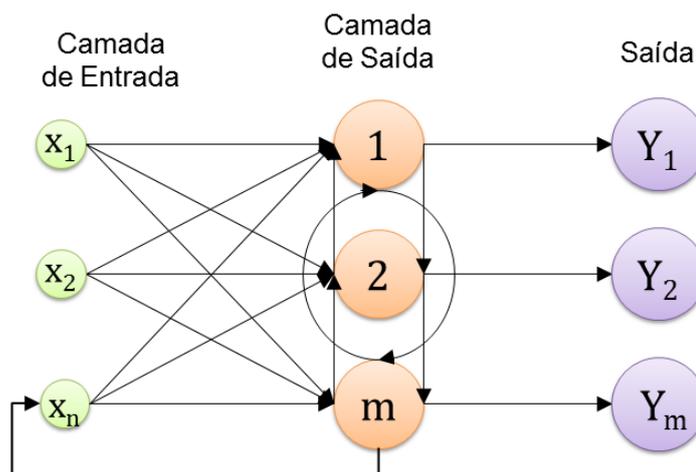


Fonte: Autor.

2.6.2.4.2.3.3 Redes Recorrentes (feed-backward)

Redes recorrentes são redes que possuem pelo menos um laço de realimentação, como está ilustrado na Figura 6. A presença de laços de realimentação tem um impacto profundo na capacidade de aprendizagem da rede e no seu desempenho devido ao seu comportamento dinâmico. Além disso, os laços de realimentação envolvem o uso de ramos particulares compostos de elementos de atraso unitário, o que resulta em um comportamento dinâmico não-linear, quando se admite que a rede neural tenha unidades não-lineares.

Figura 6 - Representação de rede neural recorrente



Fonte: Autor.

Suas principais aplicações são em sistemas dinâmicos, memória associativa, previsão e estimação, otimização e em controle. Neste tipo de redes, temos o modelo de Hopfield e o Perceptron com realimentação.

2.6.2.4.2.4 Aprendizagem da RNA

Do ponto de vista computacional, o aprendizado de máquina tenta fazer com que os programas de computador “aprendam” com os dados que eles “estudam”, tal que esses programas tomem decisões diferentes baseadas nas características dos dados estudados, usando a estatística para os conceitos fundamentais, e

adicionando heurística avançada da inteligência artificial aos algoritmos para alcançar os seus objetivos (GUIMARÃES, 2005; GUIMARÃES et al., 2001).

Em se tratando de RNA, segundo Haykin (2000), aprendizagem é um processo pelo qual os parâmetros livres (pesos sinápticos) de uma rede neural são adaptados através de um processo de estimulação pelo ambiente no qual a rede está inserida. O tipo de aprendizagem é determinado pela maneira na qual a modificação dos parâmetros ocorre.

O aprendizado é em geral um processo gradual e iterado, onde os pesos são modificados várias vezes, pouco a pouco, seguindo-se uma regra de aprendizado que estabelece a forma como estes pesos são alterados (FERRAZ, 2013). Cada iteração deste processo gradativo de adaptação dos pesos de uma rede neural, onde é feita uma apresentação completa do conjunto de dados, é chamada de época ou ciclo de aprendizado. De acordo com Osório e Bittencourt (2000) os métodos de aprendizado neural podem ser divididos em três grandes classes, segundo o grau de controle dado ao usuário: aprendizado supervisionado, semi-supervisionado e não-supervisionado.

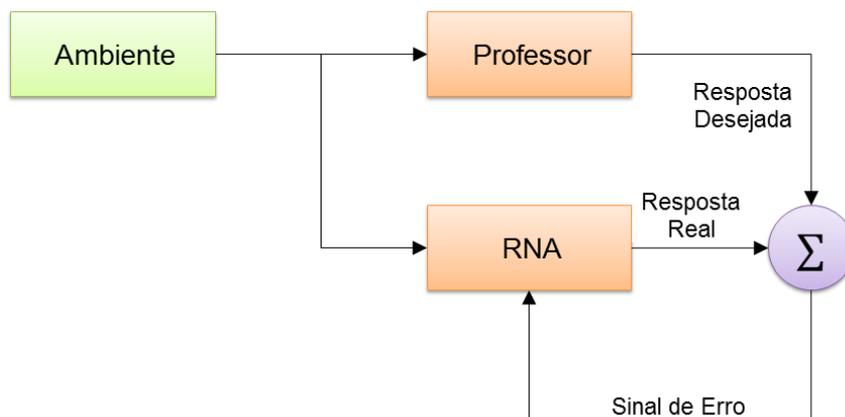
2.6.2.4.2.4.1 Aprendizado Supervisionado

O aprendizado supervisionado se dá com intervenção externa, como indicado na Figura 7. Segundo Fabri (2005), este é o método de treinamento mais comum empregado para as RNA. O método supervisionado é assim denominado pelo fato de as entradas e saídas desejadas serem fornecidas para a rede por meio de um supervisor externo denominado “professor”.

O objetivo do aprendizado consiste em ajustar os parâmetros da rede (os pesos sinápticos e as tendenciosidades), objetivando encontrar a ligação mais adequada entre pares de estímulos de entrada e saída conhecidos.

Para cada padrão de entrada submetido, será comparada a resposta desejada e a calculada pela RNA, sendo ajustados os pesos das conexões, de forma a minimizar o erro.

Figura 7 - Diagrama em blocos da aprendizagem supervisionada



Fonte: Autor (Adaptado de HAYKIN 2001).

O processo de aprendizado supervisionado tem como desvantagem o fato de que, na ausência do professor, a rede não conseguirá aprender novas estratégias para situações não cobertas pelos exemplos do treinamento da rede. Os exemplos mais conhecidos de algoritmos para aprendizado supervisionado são a regra delta (WIDROW e HOFF, 1960) e a sua generalização para redes de múltiplas camadas, e o algoritmo backpropagation (RUMELHART, et al., 1986).

2.6.2.4.2.4.2 Aprendizado não-supervisionado

No aprendizado não supervisionado a RNA é desprovida de uma saída desejada para ser utilizada no melhoramento de seu comportamento e o conjunto de treinamento consiste de somente entradas. A rede tenta, nesse caso, descobrir aspectos comuns entre as entradas separando os padrões entre si (BALESTRASSI, 2000). O processo de treinamento extrai as propriedades estatísticas do conjunto de treinamento e agrupa os vetores similares em classes. A aplicação de um vetor de entrada pertencente a uma determinada classe à entrada da RNA produzirá um vetor de saída específico. Todavia, não existe maneira de se determinar qual o padrão que será produzido na saída para um vetor de entrada de uma determinada classe antes de seu treinamento (BOCANEGRA, 2002).

2.6.2.4.2.5 Modelos de Aprendizagem

Os modelos de aprendizagem estão relacionados ao ajuste dos pesos e podem ser implementados por diferentes métodos, segundo o tipo de regra de aprendizado que for empregado. As regras de aprendizado mais usadas são (RIBEIRO, 2003; OSÓRIO e BITTENCOURT, 2000):

Aprendizagem por Correção de Erro – a rede é estimulada por um vetor de entrada e sua saída desejada. A regra de ajuste consiste em achar o erro subtraindo a resposta desejada com a resposta da rede, calculando o gradiente descendente da função do erro.

Aprendizagem Baseada em Memória – usa-se arquitetura de redes alimentadas com camada única de modo supervisionado. A maioria das amostras de treino é armazenada em uma grande memória de exemplos de entrada-saída. Um exemplo simples de aprendizagem baseada em memória é a regra do vizinho mais próximo, onde a rede classifica de acordo com a distância euclidiana entre os vetores de treino.

Aprendizagem competitiva – na camada de saída da rede, após receber as características dos objetos na camada de entrada, os neurônios competem entre si, e o neurônio que tiver o maior valor discriminante, se torna vencedor.

As regras de aprendizagem se constituem como elementos básicos para o projeto de redes neurais artificiais.

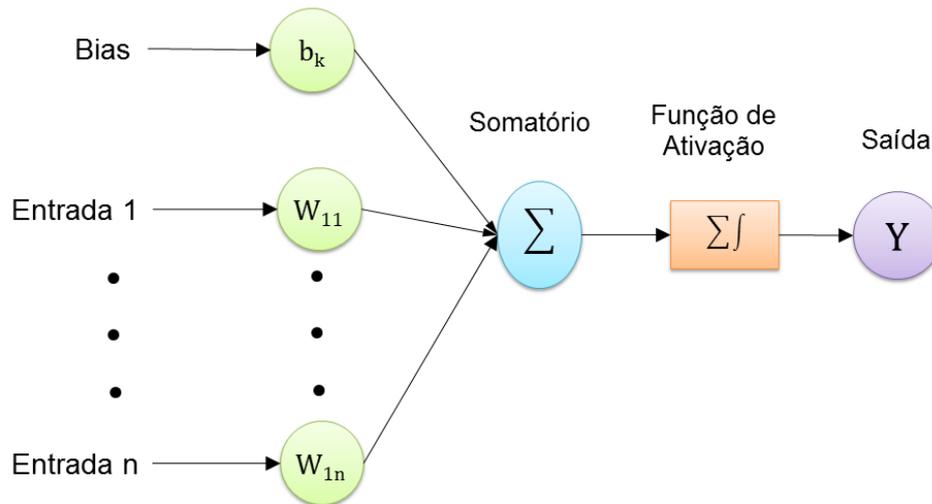
2.6.2.4.2.6 Redes Perceptron

A partir do modelo de neurônio artificial de McCulloch e Pitts (McCULLOCH e PITTS, 1943), em 1957 Rosenblatt (1958) propôs o perceptron como o primeiro modelo para aprendizagem supervisionada. O perceptron (Figura 8) é a forma mais simples de uma RNA usada para classificação de padrões ditos linearmente separáveis. Basicamente, ele consiste em um único neurônio com pesos sinápticos ajustáveis e bias (HAYKIN, 2001)

Valença (2010) define que a rede perceptron é composta por uma camada de entrada onde estão as informações que alimentam a rede, uma função de pesos e uma função de saída, também conhecida como função de ativação que fornece o sinal emitido pelo neurônio da camada de saída.

O perceptron pode ser visto como ferramenta para reconhecimento de padrões. Reconhecer um padrão consiste em classificar este como sendo pertencente a uma única classe dentre um conjunto de classes pré-estabelecidas.

Figura 8 - Estrutura de rede neural do tipo perceptron de única camada



Fonte: Autor (Adaptado de HAYKIN 2001).

A principal limitação do perceptron é que este pode classificar somente conjunto de dados linearmente separáveis e tem como função de ativação da tipo degrau, o que fornece apenas um sinal discreto (sim ou não) (NAGAOKA, 2003; BRAGA et al., 2000).

2.6.2.4.2.7 Rede Perceptron de Múltiplas Camadas (MLP)

A rede perceptron de múltiplas camadas é um sistema de neurônios ligados por conexões sinápticas dividido em neurônios de entrada, que recebem estímulos do meio externo, neurônios internos ou *hidden* (ocultos) e neurônios de saída, que se comunicam com o exterior (BEALE e JACKSON, 1994). O MLP foi concebido para resolver problemas mais complexos, os quais não poderiam ser resolvidos pelo modelo de neurônio básico.

Conforme Valença (2010) as redes MLP tradicionais apresentam as seguintes características:

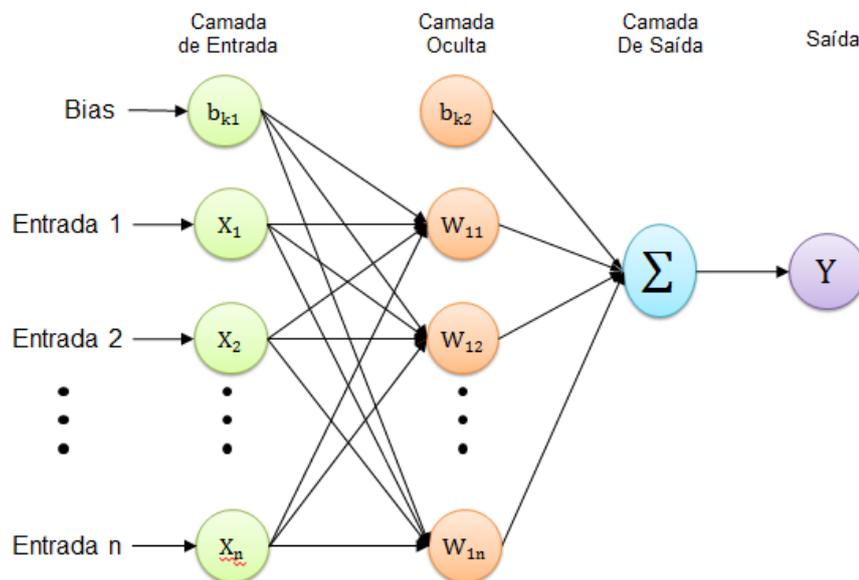
- Camada de entrada: cada neurônio desta camada corresponde a uma variável de entrada do problema;

- Camada intermediária: é a camada responsável de pela não linearidade da rede e permitem que as redes MLP sejam capazes de resolver problemas reais. Os neurônios desta camada possuem, normalmente, uma função de ativação sigmoide logística ou tangente hiperbólica.

- Camada de saída: esta camada é responsável pela resposta da rede e representa a variável desejada.

Um exemplo de estrutura de redes neurais de múltiplas camadas está exposto na Figura 9.

Figura 9 - Rede neural artificial multicamadas (Multilayer Perceptron)



Fonte: Autor.

As camadas intermediárias funcionam como extratoras de características, seus pesos são codificações das informações apresentadas nos padrões de entrada e permitem que a rede crie sua própria representação, mais rica e detalhada, do problema (SILVA, 1997).

A rede neural passa por um processo de treinamento a partir dos casos reais conhecidos, adquirindo, a partir daí, a sistemática necessária para executar adequadamente o processo desejado dos dados fornecidos. Sendo assim, a rede neural é capaz de extrair regras básicas a partir de dados reais, diferindo da computação programada, onde é necessário um conjunto de regras rígidas prefixadas e algoritmos.

As redes MLP são também redes de treinamento supervisionado de tal forma que o problema encontrado durante o treinamento destas é que, com a inclusão de pelo menos uma camada intermediária não se conhece o erro destas camadas necessário para realizar o reajuste dos pesos. Logo, o algoritmo backpropagation resolve este problema por realizar uma propagação recursiva dos erros. (VALENÇA, 2010). Este algoritmo é baseado numa regra de aprendizagem que corrige o erro durante o treinamento (HAYKIN, 1999).

2.6.2.4.2.7.1 Algoritmo Backpropagation

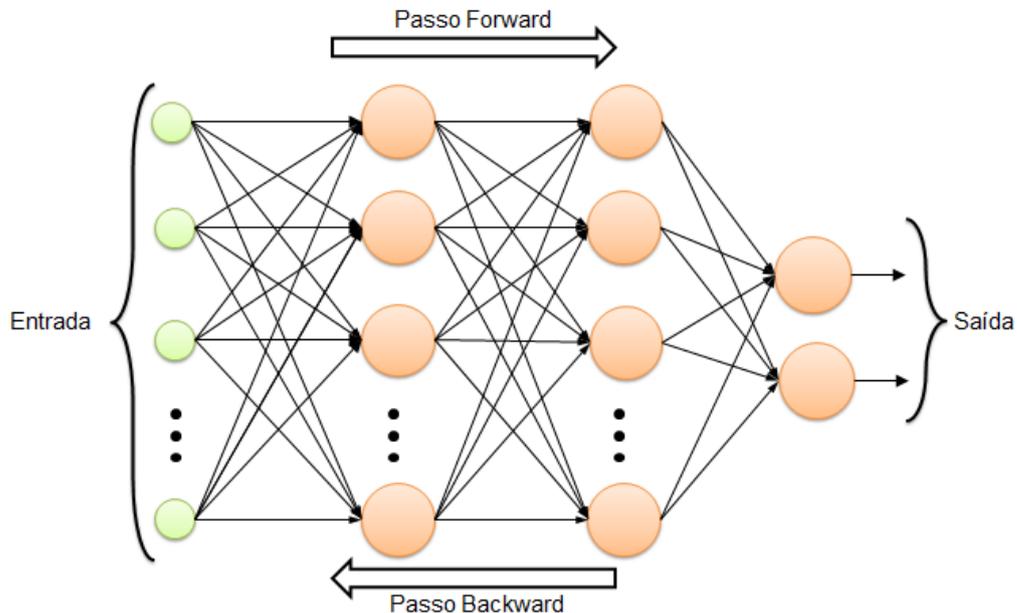
O algoritmo de aprendizado mais conhecido para treinamento destas redes é o algoritmo backpropagation (RUMELHART e McCLELL, 1986). Este algoritmo teve a sua origem no trabalho desenvolvido por Paul Werbos, em 1974. Entretanto, sua popularização ocorreu apenas na década de 80, através dos trabalhos de Geoffrey Hinton, David Rumelhart e Ronald Willimas (VALENÇA, 2010).

O algoritmo de treinamento consiste basicamente em dois passos: no primeiro propagam-se os sinais no sentido progressivo (da camada de entrada para a camada de saída), calculando-se o sinal de saída e o erro. Os pesos permanecem fixos; no segundo passo, os erros são propagados recursivamente (da camada de saída para a camada de entrada) através da rede e os pesos são ajustados através da regra de ajustes de pesos.

Dentre as características que norteiam o funcionamento do algoritmo de aprendizado backpropagation, um detalhe importante é a repetição (ciclos) em um determinado número de vezes (x) que o par amostra-resultado (saída) é submetido para que a rede possa, efetivamente, aprender. Estas repetições são chamadas épocas de treinamento (ciclos).

Esses processos também são conhecidos como Passo Forward e Backward (BRAGA et al, 2000) e está representado na Figura 10.

Figura 10 - Fluxo do algoritmo Back-propagation.



Fonte: Autor (Adaptado de Ferraz, 2013).

Na atualização dos pesos sinápticos, o algoritmo backpropagation fornece também uma aproximação, cujo parâmetro é um índice variando entre 0 (zero) e 1 (um), chamado de *taxa de aprendizagem*, o qual tem por finalidade determinar quanto do valor atual da sinapse será alterado na próxima época. Quanto menor for este parâmetro, menor serão as variações dos pesos sinápticos da rede, de uma iteração para a outra, e mais suave será a trajetória no espaço de pesos. Esta melhoria, entretanto, é obtida à custa de uma evolução de aprendizagem lenta. Por outro lado, caso utilize-se um parâmetro muito alto, para acelerar a aprendizagem, as grandes modificações nos pesos resultantes podem tornar a rede instável (oscilatória) (HAYKIN, 2001).

Outra forma de atualização dos pesos é não utilizar uma taxa fixa, mas variável. Em alguns casos, pode-se orientar o algoritmo para que, quanto mais próximo estiver do valor ideal do peso, menor a taxa de atualização ou aprendizagem. Também pode ser utilizado, na atualização do peso, uma parcela proporcional à atualização anterior, denominado *momento* ou *inércia* (MEDEIROS, 2003).

Com o desenvolvimento do algoritmo de treinamento (backpropagation) foi possível treinar redes com camadas intermediárias, sendo atualmente a rede

perceptron multicamadas uma das mais utilizadas em problemas de identificação de sistemas.

O Backpropagation é um algoritmo de aprendizagem eficiente e utilizado por diversos autores, porém sua implementação normalmente exige muitos passos e, assim, um tempo de treinamento maior, visto que este pode aumentar de forma superlinear, polinomial ou exponencialmente à medida que mais entradas são inseridas (ZHAO, 1996). Há muitos estudos, baseados em heurísticas e em técnicas de otimização, para apressar a convergência do algoritmo, com o objetivo de melhorar sua eficiência em relação ao tempo de treinamento (ANDRADE et al., 2003).

2.6.2.4.3 Máquinas de vetores de suporte (MVS)

As Máquinas de Vetores Suporte (Support Vector Machines- SVMs) constituem uma técnica embasada de Aprendizado Estatístico (VAPNIK, 1995) que vem recebendo grande atenção nos últimos anos (HEARST et al., 1998; CRISTIANINI; SHAW-TAYLOR, 2000).

A MVS é um sistema de aprendizado que discrimina um conjunto de amostras de teste dividindo-o em dois grupos (é um classificador binário em sua formulação original), e se baseia na teoria de aprendizado estatístico e na teoria de otimização. A teoria matemática de otimização tem sido usada em várias áreas da ciência (economia, mecânica, física entre outras) (BARTHELEMY e HAFTKA, 1993).

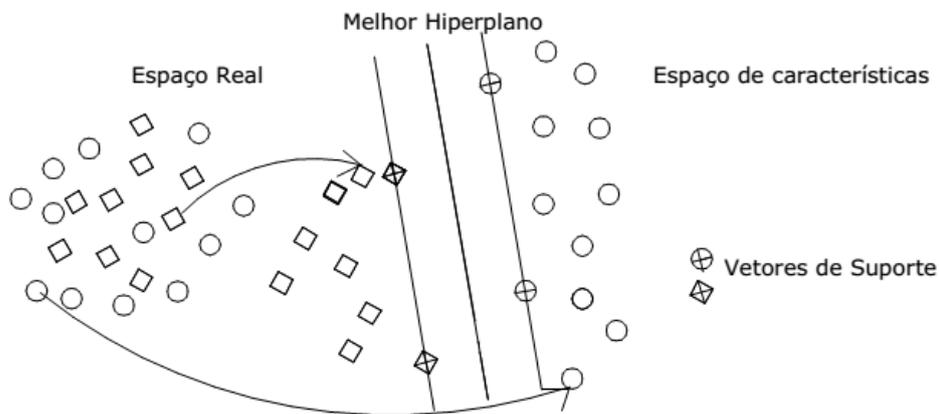
Os resultados da aplicação de MVS são comparáveis aos obtidos por outros algoritmos de aprendizado, como as Redes Neurais Artificiais (RNA) (HAYKIN, 1999), e em algumas tarefas têm se mostrado superiores, tal como na detecção de faces em imagens (HEARST et al., 1998), na categorização de textos (HEARST et al., 1998) e em aplicações em Bioinformática (ZIEN et al., 2000).

Visto que RNA apresentam problemas como: algoritmos de aprendizagem envolvendo geralmente um grande número de exemplos de treinamento, longos períodos de treinamento, ocorrência de mínimos locais e arquitetura definida a partir de experimentos, em MVS o treinamento encontra uma solução global, enquanto que em RNA há geralmente mínimos locais. Em MVS há a minimização do risco empírico, como em RNA, juntamente com a Minimização do Risco Estrutural, equivalente à minimização do erro de generalização, que envolve a imposição de um

limite para diminuir ao máximo a possibilidade de classificações erradas na etapa de teste.

As Máquinas de Vetores de Suporte promovem a transformação dos dados de entrada num grande espaço característico m -dimensional, usando um mapeamento não linear, onde são selecionados vetores de suporte à previsão (Figura 11) (CORTES e VAPNIK, 1995; CORTEZ, 2010). As MVS procuram o melhor hiperplano de separação linear, relativo a um conjunto de vetores de suporte, no espaço característico. A transformação depende da função kernel $k(x,y)$ adotada.

Figura 11 - Exemplo de transformação MVS



Fonte: Martins, 2012.

O Aprendizado de Máquina (AM) é um campo de pesquisa da Inteligência Computacional que estuda o desenvolvimento de métodos capazes de extrair conceitos (conhecimento) a partir de amostras de dados (MITCHELL, 1997).

Em geral, os diversos algoritmos de AM são utilizados de forma a gerar classificadores para um conjunto de exemplos. Por classificação entende-se o processo de atribuir, a uma determinada informação, o rótulo da classe a qual ela pertence (RUSSEL e NORVIG, 1995). A classe de um exemplo (instância) descreve o fenômeno de interesse, ou seja, o que se deseja aprender e fazer previsões (BARANAUSKAS; MONARD, 2000).

Portanto, as técnicas de AM são empregadas na indução (a partir de um conjunto de treinamento) de um classificador, que deve ser capaz (idealmente) de prever a classe de instâncias quaisquer do domínio em que ele foi treinado.

As técnicas tradicionais são muito focadas para a minimização do risco empírico, ou seja, em tentar otimizar o desempenho de um conjunto treino. O risco depende da complexidade do conjunto de funções escolhidas, bem como do conjunto treino. Já as MVS tentam reduzir o risco estrutural, isto é, a probabilidade de ocorrer classificação errada de padrões segundo uma probabilidade de distribuição de dados fixa, mas desconhecida. Desta forma os resultados da aplicação desta técnica podem ser comparáveis e muito vezes superiores aos obtidos por outros algoritmos de aprendizagem, como por exemplo as RNA (MAIMON; LIOR, 2010).

O processo de treino das MVS consiste na obtenção de valores para os pesos que definem um “hiperplano” ideal de mapeamento, de forma a minimizar a função de custo, num processo semelhante ao que ocorre nas RNA (PONTIL; VERRI, 1998). A diferença, é que no caso das MVS é garantido que os pesos são ótimos, sendo que a não linearidade é garantida via uma função de kernel, que transforma o espaço original das entradas num espaço imaginário, de modo que neste espaço a separação seja do tipo linear.

Martins (2012) comparou os desempenhos das RNA e das MVS na previsão dos fatores de segurança de estabilidade de taludes, obtendo para a base de dados utilizada, que os métodos não lineares baseados em Máquinas de Vetores de Suporte conduziram a uma melhor estimativa do fator de segurança e efetuaram uma melhor avaliação da estabilidade dos taludes.

2.6.2.4.3.1 Histórico das MVS

Os fundamentos de MVS são provenientes da Teoria de Aprendizagem Estatística desenvolvida inicialmente pelo pesquisador russo Vladimir Vapnik e colaboradores (VAPNIK, 1999). O autor idealizou o princípio indutivo de Minimização do Risco Estrutural. Este princípio busca minimizar o erro do conjunto de treinamento (risco empírico), juntamente com o erro do conjunto de teste. Segundo Vapnik (1999), a motivação para o desenvolvimento do princípio indutivo de Minimização do Risco Estrutural surgiu da necessidade de desenvolver limites teóricos para a capacidade de generalização dos sistemas de aprendizagem. Uma maior generalização normalmente implica um maior número de acertos na fase de teste. O princípio de Minimização do Risco Empírico, utilizado em técnicas como

Redes Neurais, era considerado pelos seus defensores como sendo de fácil intuição e que, por apresentar bons resultados práticos, não necessitava de provas teóricas. Para esses defensores, uma boa generalização era obtida unicamente através da escolha de pesos para os neurônios de modo a prover um erro de treinamento mínimo.

Entretanto, para a análise teórica do processo de aprendizagem, esse conceito era visto de forma diferente. Em Vapnik (1999), o autor afirma que o princípio de minimização do número de erros de treinamento não é evidente e precisa ser justificado, pois pode haver outro princípio indutivo com nível de habilidade de generalização superior, e que este é o principal objetivo da análise teórica, para que se possa construir algoritmos que implementem tal princípio.

Santos (2002) relata que as respostas para essas pesquisas foram o princípio indutivo de Minimização do Risco Estrutural e as Máquinas de Vetores de Suporte (Support Vector Machines) que realizam esse princípio.

Embora as pesquisas desenvolvidas com MVS sejam recentes, as raízes do método foram formuladas na década de 70. Houve uma paralização nas pesquisas por mais de três décadas.

Em Cristianini e Shawe-Taylor (2000) os autores destacam dois problemas encontrados no período inicial, do ponto de vista algorítmico, que podem justificar essa parada nas pesquisas: 1 - o algoritmo original (VAPNIK E CHERVONENKIS, 1964) era limitado à problemas de aprendizagem linearmente separáveis; 2 - não apresentava uma forma de tratar com dados isolados ou muito distantes do padrão original, os "outliers".

Os dois problemas citados anteriormente foram solucionados durante a década de 90. O primeiro com o uso de funções kernel, que fazem o mapeamento dos dados do espaço de entrada para um espaço de características com uma dimensão muito superior, possibilitando que os dados não separáveis linearmente, tornem-se separáveis no espaço de características.

A ideia de utilização de funções kernel foi empregada pela primeira vez em 1964, no mesmo período em que Vapnik e Chervonenkis desenvolveram a idéia do hiperplano de separação ótima. Este hiperplano separa as diferentes classes, maximizando a margem entre os pontos extremos de cada classe. O uso combinado desses dois conceitos na formulação de MVS foi apresentado por Boser et al. (1992). O segundo problema foi solucionado através da introdução de variáveis de

folga para dar mais flexibilidade às restrições e permitir a classificação correta dos "outliers".

Entretanto, Vapnik (1999) afirma que as pesquisas não paralisaram. Em 1974 foram obtidos os limites para a introdução de um possível novo princípio indutivo (Minimização do Risco Estrutural), completando o desenvolvimento da teoria de aprendizagem para Reconhecimento de Padrões. Vapnik (1999) afirma que após 30 anos de análise do processo de aprendizagem, nos anos 90 começou a síntese das novas máquinas de aprendizagem capazes de controlar a habilidade de generalização.

Nos últimos anos ocorreram desenvolvimentos significativos na compreensão teórica de MVS, em estratégias algorítmicas para implementá-lo e aplicações da técnica a diversos problemas práticos. Entretanto, ainda não há estudos das aplicações de MVS para resolução de problemas relacionados ao meio agrícola.

2.6.2.4.3.2 Aprendizado com MVS

A Máquina de Vetor de Suporte é uma técnica de aprendizado de máquina fortemente embasada nos conceitos de aprendizado de máquina estatística. Sua formulação é totalmente matemática (teoria da otimização matemática), mas incorpora a definição de limites superiores na capacidade de generalização.

Nas MVS, assim como nas RNA, a condução de aprendizagem pode se dividir em duas as formas:

- Aprendizado Supervisionado
- Aprendizado Não-Supervisionado

Quando se fala em aprendizado supervisionado, temos amostras de treinamento já previamente identificadas ou classificadas. Assim, o objetivo é treinar o sistema de tal forma que ele possa identificar padrões.

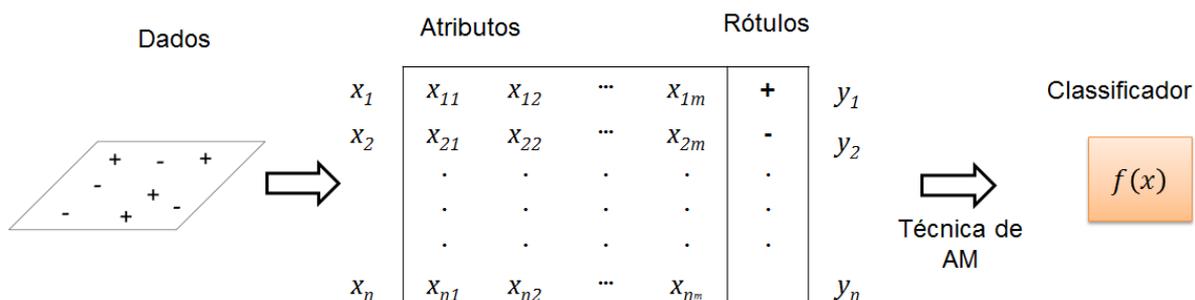
2.6.2.4.3.3 Teoria do aprendizado estatístico (TAE)

Segundo Vapnik (1998) a Teoria VC (Vapnik-Chervonenkis), abrange quatro partes importantes para sua implementação: a Teoria da Consistência dos Processos de Aprendizagem, Teoria da Taxa de Convergência dos Processos de Aprendizagem, Teoria da Minimização do Risco Estrutural, e Teoria da Otimização,

que são sintetizadas e apresentadas a seguir de acordo Brito Filho (2012).

Tendo dados de treinamento $\{(x_1, y_1), \dots, (x_n, y_n)\}$, conforme a Figura 12, $\in R^n \times Y$, assume-se inicialmente que eles são gerados de forma independente e identicamente distribuído (i.i.d.), de acordo com a probabilidade $P(x, y)$, que descreve a relação entre seus dados x e rótulos y . Sendo f um modelo e F um conjunto de todos os modelos que um algoritmo pode gerar. Este, durante o processo de aprendizagem, utiliza um processo de treinamento T , composto de n pares (x_i, y_i) , para gerar um modelo particular $j \in F$.

Figura 12 - Esquema da geração de um classificador



Fonte: Autor (Adaptado de Lorena e Carvalho, 2007).

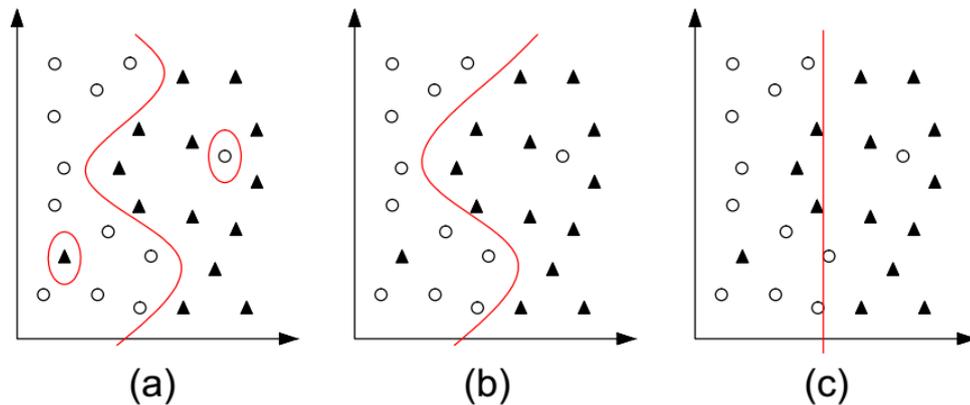
O objetivo de um processo de aprendizagem é encontrar um modelo, por exemplo, que separara os dados de treinamento “-” e “+”. Através de funções de separação (limites de decisão) as classes são separadas.

A Figura 13(a) ilustra uma hipótese que classifica corretamente todos os exemplos do conjunto de treinamento, incluindo dois possíveis ruídos. Por ser muito específica para o conjunto de treinamento, essa função apresenta elevada susceptibilidade a cometer erros quando confrontada com novos dados. Esse caso representa a ocorrência de um superajustamento do modelo aos dados de treinamento.

Na Figura 13(c) temos outro classificador que comete muitos erros mesmo para casos que podem ser considerados simples. Tem-se assim a ocorrência de um subajustamento, pois o classificador não é capaz de se ajustar mesmo aos exemplos de treinamento.

A Figura 13(b) é um meio termo entre as duas funções descritas é um classificador com complexidade intermediária e classifica corretamente grande parte dos dados, sem se fixar demasiadamente em qualquer ponto individual.

Figura 13 - Diferentes hipóteses de configuração de treinamento



Fonte: Autor (Adaptado de Mendoza, 2009).

Na aplicação da TAE, assume-se inicialmente que os dados do domínio em que o aprendizado está ocorrendo são gerados de forma independente e identicamente distribuída de acordo com uma distribuição de probabilidade $f(x; y)$, que descreve a relação entre os dados (x) e os seus rótulos (y). O erro (risco) esperado de um classificador f denotado por $R(f)$, para dados de teste, pode então ser quantificado pela Equação 2

2.6.2.4.3.4 Risco

O risco $R(g)$, também denominado erro, foi definido por *Vapnik* (1995) como a probabilidade de classificação incorreta, tendo como argumento uma função $g(\cdot)$. O risco esperado mede então a capacidade de generalização de g , para os dados de teste, segundo a Equação 2, sendo $c(g(x), y)$ uma função custo relacionada a previsão $g(x)$ quando a saída desejada é y e $P(x, y)$ uma medida de probabilidade:

$$R(g) = \int c(g(x), y) dP(x, y) \quad (2)$$

Exemplificando, uma função custo utilizada em problemas de classificação, $\frac{1}{2}|y - g(x)|$, retorna 0 caso a classificação seja correta e 1 caso contrário. Uma função comumente utilizada em problemas de regressão é $(y - g(x))^2$.

A função de risco empírico g , dada pela Equação 3, retorna a taxa de erro médio do treinamento em T , medindo seu desempenho.

$$R_{emp}(g) = \frac{1}{N} \sum_{i=1}^N c(f(x_i), y_i) \quad (3)$$

Em geral, a distribuição de probabilidade $P(x_i, y_i)$ não é conhecida, não sendo possível minimizar a Equação 2. O que é conhecido são as informações dos dados de treinamento, também amostrados de $P(x_i, y_i)$. Logo, deve-se recorrer à minimização do risco empírico (Equação 3) e espera-se que esse procedimento também diminua o erro sobre os dados de teste. Com um conjunto grande de dados, fazendo-se $n \rightarrow \infty$ é possível fazer o $R_{(emp)}$ convergir para o $R_{(g)}$, mas com conjuntos de dados pequenos não é possível. Como os dados de treinamento têm densidade amostral fixa, pois correspondem a uma amostra da população, a relação entre os funcionais $R(g)$ e $R_{emp}(g)$ será determinada pela função g .

Tendo um conjunto F , sempre é possível encontrar uma função f , com risco empírico pequeno, pois a tarefa de calcular este risco reduz-se a uma simples média, como por exemplo, o erro médio quadrático. A TAE (Teoria do Aprendizado Estatístico) provê diversos limites no risco esperado de uma função f , pois os exemplos de treinamento podem se tornar pouco informativos para a tarefa de aprendizado, podendo ser empregados na escolha do melhor classificador.

2.6.2.4.3.5 Classificação com MVS

O problema de classificação pode ser restrito ao problema de duas classes, sem perda de generalidade (GUNN, 1998)

Uma SVC acha o melhor hiperplano de separação entre as duas classes de amostras de treinamento, no espaço de características, com margem máxima

(MAVROFORAKIS; THEODORIDIS, 2006). O objetivo é produzir um classificador que funcione bem com exemplos não conhecidos, ou seja, um classificador que generaliza bem.

Uma função do tipo linear (Equação 4), correspondente ao hiperplano, separa o espaço de características. Denotando-se $y_i \in \{+1, -1\}$ como o valor numérico das saídas, x_i os vetores de entrada, $i = 1, \dots, N$, w o vetor de pesos e m a margem máxima, o problema de classificação é equivalente a achar o funcional f , que satisfaça $y_i((w, x_i) + b) \geq m$ que maximize m .

$$f(x) = (W \cdot x) + b \quad (4)$$

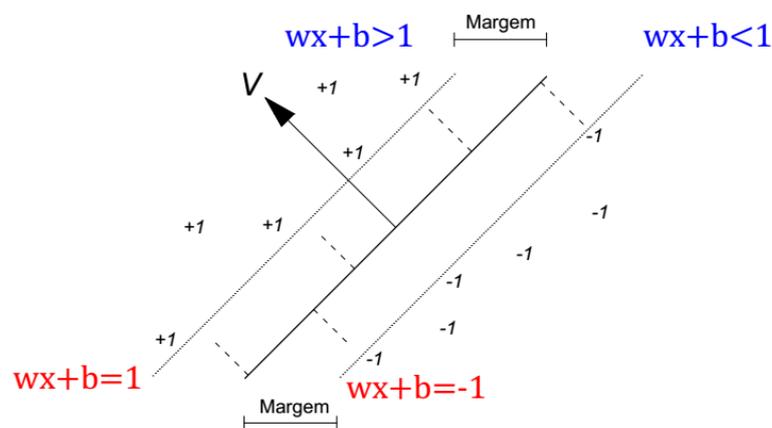
Em termos geométricos, achar o hiperplano que maximize a margem $\frac{m}{\|m\|}$, sendo

$H(w, b): (w, x) + b = 0$, é satisfazer $y_i \left(\frac{(w, x_i)}{\|m\|} + \frac{b}{\|m\|} \right) \geq \frac{m}{\|m\|}$ para todos os

exemplos de treinamento, onde $\|m\|$ é a norma Euclidiana da distância máxima. A margem geométrica (Figura 14) representa a distância mínima dos exemplos de treinamento para as duas classes, separadas pelo hiperplano H . Assumindo $m = 1$, chamado hiperplano canônico, o problema de classificação torna-se equivalente a forma $H(w, b): (w, x) + b = 0$, maximizando a margem total $\frac{1}{2}(\|w\|^2)$ e satisfazendo a Equação 5.

$$y_i((w, x_i) + b) \geq 1 \quad (5)$$

Figura 14 - Separação por hiperplanos de margem máxima



Fonte: Autor (Adaptado de Brito Filho, 2012).

O problema relacionado acima é de otimização quadrática (adotando-se a norma euclidiana), com restrições de desigualdade linear e abordagem algébrica, e por padrão, a solução é uso do método dos multiplicadores de Lagrange (Equação 6) (MINOUX, 1986):

$$L = \frac{1}{2} |W|^2 - \sum_{i=1}^N \alpha_i \{[(w \cdot x_i) + b]y_i - 1\} \quad (6)$$

onde α_i ($i = 1, \dots, N$) são os multiplicadores de Lagrange. O lagrangeano da Equação 6 tem que ser minimizado com respeito a w e b e maximizado com respeito a α_i . O problema de otimização dual é equivalente a maximizar (Equação 7):

$$L_{max} = \sum_i \alpha_i - \frac{1}{2} \sum_i \sum_j y_i y_j \alpha_i \alpha_j (x_i \cdot x_j) \quad (7)$$

tendo como restrições $\alpha_i \geq 0$ e $\sum_i y_i \alpha_i = 0$; então a Equação 8 representa a solução produzida.

$$\alpha = \arg \min \left[\frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j y_i y_j (x_i \cdot x_j) - \sum_{i=1}^N \alpha_i \right] \quad (8)$$

Considerando as restrições impostas a Equação 8, a solução resultante (Equações 9 e 10):

$$w = \sum_{i=1}^N \alpha_i x_i y_i \quad (9)$$

$$b = -\frac{1}{2} ((w \cdot x_r) + (w \cdot x_s)) \quad (10)$$

Onde: x_r e x_s são os vetores de suporte da classe dada.

As condições de Karush-Kuhn-Tucker (KUHN, 2006), que são condições

necessárias e suficientes, estabelecem que as soluções ótimas α^* , w^* e b^* devem satisfazer a seguinte igualdade:

$$\alpha^* \left[y_j \left((w^* \cdot x_j) + b^* \right) - 1 \right] = 0 \quad (11),$$

para $j = 1, 2, \dots, N$.

Com base na Equação 11 acima, observam-se que os pontos $y_i \left((w \cdot x_j) + b \right) = 1$ devem ter necessariamente $\alpha = 0$. Só os pontos com margem 1 podem ter os correspondentes $\alpha = 0$, chamados vetores-suporte (SVs).

2.6.2.4.3.6 MVS com margens suaves

Em situações reais, é difícil encontrar aplicações cujos dados sejam linearmente separáveis. Isso se deve a diversos fatores, entre eles a presença de ruídos e *outliers* (discrepância) nos dados ou à própria natureza do problema, que pode ser não linear. Nesta seção as MVS lineares de margens rígidas são estendidas para lidar com conjuntos de treinamento mais gerais. Para realizar essa tarefa, permite-se que alguns dados possam violar a restrição da Equação 5. Isso é feito com a introdução de variáveis de folga ξ_i , para todo $i = 1, \dots, n$ (SMOLA; SCHÖLKOPF, 1999). Essas variáveis relaxam as restrições impostas ao problema de otimização primal, que se tornam segundo Smola e Schölkopf (2002) a Equação 12 a seguir.

$$y_j \left((w^* \cdot x_j) + b^* \right) \geq 1 - \xi_i, \quad \xi_i \geq 0, \forall i = 1, \dots, n \quad (12)$$

A aplicação desse procedimento suaviza as margens do classificador linear, permitindo que alguns dados permaneçam entre os hiperplanos H1 e H2 e também a ocorrência de alguns erros de classificação. Por esse motivo, as MVS obtidas neste caso também podem ser referenciadas como MVS com margens suaves.

Um erro no conjunto de treinamento é indicado por um valor de ξ_i maior que 1. Logo, a soma dos ξ_i representa um limite no número de erros de treinamento. Para levar em consideração esse termo, minimizando assim o erro sobre os dados de

treinamento, a função objetivo da Equação 13 é reformulada como:

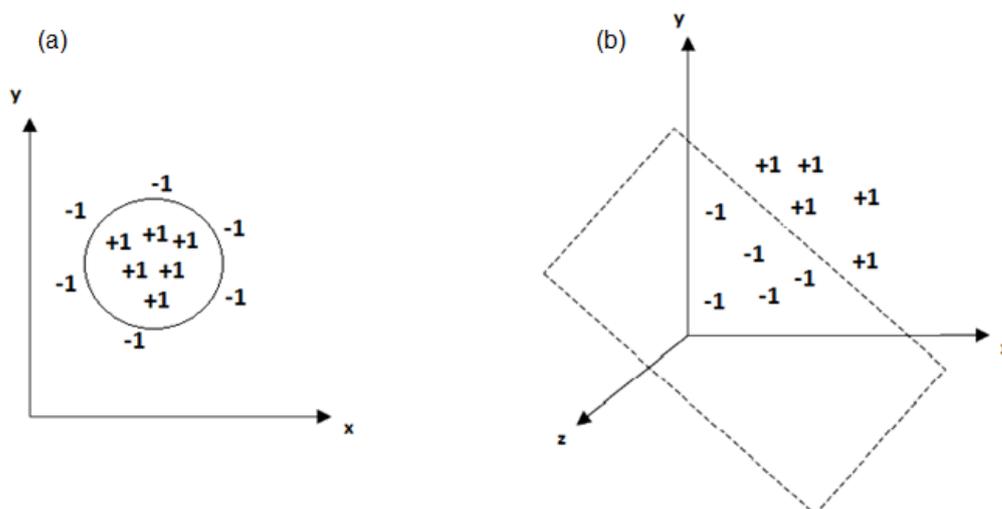
$$\underset{w,b,\xi}{\text{Minimizar}} \frac{1}{2} \|w\|^2 + C \left(\sum_{i=1}^N \xi_i \right) \quad (13)$$

A constante C é um termo de regularização que impõe um peso à minimização dos erros no conjunto de treinamento em relação à minimização da complexidade do modelo (PASSERINI, 2004). A presença do termo $(\sum_{i=1}^N \xi_i)$ no problema de otimização também pode ser vista como uma minimização de erros marginais, pois um valor de $\xi_i \in (0, 1]$ indica um dado entre as margens.

2.6.2.4.3.7 Regressão com MVS

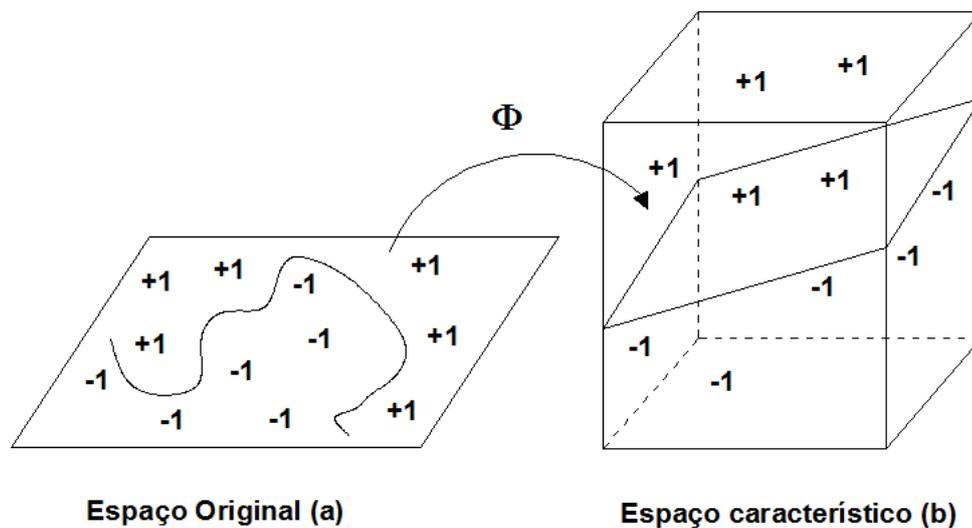
Existem casos que não é possível utilizar as MVS com separação linear ou mesmo as com margens flexíveis, pois teriam resultados insatisfatórios na divisão dos exemplos de treinamento, como por exemplo na Figura 15a, em que o emprego de uma função circular seria mais apropriado ou na Figura 15b, em que uma função linear, no espaço de características seria mais apropriada (BRITO FILHO, 2012).

Figura 15 - Representação de emprego de Função circular (a) e Função linear em R^3 (b)



As Regressões de Vetores de Suporte - RVS (*Support Vector Regression – SVR*) tratam de problemas não lineares mapeando seu conjunto de treinamento de seu espaço original, associado às entradas, para um novo espaço dimensional, mais complexo, denominado espaço de características ou espaço característico (HEARST, 1998), como na Figura 16.

Figura 16 - Mudança do espaço original para o de características



Fonte: Autor (Adaptado de Brito Filho, 2012).

De acordo com Müller et al. (2001) o mapeamento não-linear funciona da seguinte forma:

Definição:

$$\Phi: R^N \rightarrow \mathfrak{F}$$

$$x \rightarrow \Phi(x)$$

Sendo $x_1, \dots, x_n \in R^n$ são mapeados em um espaço de características potencialmente muito maior de dimensões \mathfrak{F} . Para um determinado problema de aprendizado, passou-se a considerar o mesmo algoritmo \mathfrak{F} em vez de R^n , ou seja, trabalha-se com a amostra:

$$(\Phi(x_1), y_1), \dots, (\Phi(x_n), y_n) \in \mathfrak{F} \times Y$$

Em \mathfrak{S} podem ser encontrados tanto dados mapeados de uma simples classificação quanto de uma regressão. Implicitamente, tem a mesma função que uma camada escondida de uma rede neural *Multi Layer Perceptron* (MLP) (HAYKIN, 1999), uma rede *Radial Basis Function* (RBF) ou algoritmos de *boosting* (FREUND; SCHAPIRE, 1997) onde os dados de entrada são mapeados para alguma representação dada pela camada escondida.

A adversidade conhecida como dimensionalidade das estatísticas, diz essencialmente que a dificuldade de um problema de estimação aumenta drasticamente com a dimensão N do espaço. Em princípio, são necessários exemplos de ordem exponencial para provar que o espaço é adequado. Esta afirmação, bem conhecida, induz a uma dúvida: É uma boa idéia usar um espaço dimensional maior como recurso de aprendizagem?

Porém, a teoria de aprendizagem estatística nos afirma que o oposto pode ser verdade: a aprendizagem em \mathfrak{S} pode ser mais simples usando-se uma baixa complexidade, ou seja, classificadores lineares, por exemplo. Toda a variabilidade e riqueza é introduzida então pelo mapeamento Φ .

Demonstrando os conceitos introduzidos, tomando os dados do exemplo da Figura 16a e modificando seu espaço dimensional, de R^2 para R^3 , tendo como função de mapeamento (Equação 14):

$$\Phi(x) = (x, y) = x^2 + \sqrt{2} x \cdot y + y^2 \quad (14)$$

é possível encontrar um hiperplano no espaço tridimensional (Figura 16-b), separando os dados convenientemente (Equação 15):

$$f(x) = w \cdot \Phi(x) + b = w_1 x^2 + w_2 \sqrt{2} x \cdot y + w_3 y^2 + b = 0 \quad (15)$$

No espaço em R^3 , a função de separação é linear (Figura 16-b), embora em R^2 também poderia ser.

Após encontrar o hiperplano ótimo, com maior margem de separação, em Φ ,

utiliza-se a abordagem das MVS com margens flexíveis, com as variáveis ξ , que permite lidar melhor com dados ruidosos. Aplica-se Φ aos exemplos de problema de otimização com as mesmas restrições, conforme a Equação 16 abaixo:

$$\max(\alpha) = \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i,j=1}^N \alpha_i \alpha_j y_i y_j (\Phi(x_i) \cdot \Phi(x_j)) \quad (16)$$

A partir do problema Equação 16 tem-se a Equação 17:

$$\alpha = \arg \min_{\alpha} \left[\frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j y_i y_j \phi(x_i, x_j) - \sum_{k=1}^N \alpha_k \right] \quad (17)$$

onde $\phi(x_i, x_j)$ é uma função kernel, que representa o mapeamento não-linear que leva ao espaço de características. Assim, é extraído o classificador que implementa o hiperplano ótimo (Equação 18):

$$g(x) = \text{sgn}(f(x)) = \text{sgn} \left(\sum_{SVs} \alpha_i^* y_i \phi(x_i, x) + b^* \right) \quad (18)$$

onde:

$$(w^* \cdot x) = \sum_{i=1}^N \alpha_i y_i \Phi(x_i, x) \quad (19)$$

$$b^* = -\frac{1}{2} \sum_{SVs} \alpha_i^* y_i [\Phi(x_r, x_i) + \Phi(x_s, x_i)] \quad (20)$$

2.6.2.4.3.8 Funções kernel

Como o processo de treinamento das MVS consiste na obtenção de valores para os pesos que definem um “hiperplano” ideal de mapeamento, a função kernel é

o argumento que vem a garantir a otimização destes pesos sem que se perca a garantia de não linearidade. A função kernel é responsável por transformar o espaço original das entradas num espaço imaginário, de modo a que neste espaço a separação seja do tipo linear (PONTIL; VERRI, 1998).

Tendo-se que (Equação 21):

$$K(x_i, x_j) = \Phi(x_i, x_j) \quad (21)$$

define-se um kernel K como sendo uma função que recebe dois argumentos x_i e x_j do espaço de entradas de dados e calcula o produto escalar desses argumentos no espaço de características (HAYKIN, 1999)

A construção do mapeamento Φ é implícita, pois se utiliza o kernel sem conhecê-la, tornando seu uso mais simplificado.

São utilizadas funções kernel que seguem os princípios do Teorema de Mercer (PASSERINI, 2004) garantindo o cálculo do produto escalar na Equação 20. e a convexidade na Equação 16. Na Tabela 3 encontram-se alguns tipos de funções kernel:

Tabela 3 - Tipos de funções kernel

Tipo de kernel	Função $K(x_i, x_j)$
Linear	$(x_i, x_j) + 1$
Polinomial	$((x_i, x_j) + 1)^p$
RBF	$\exp(-\gamma \ x_i - x_j\ ^2)$
Sigmoidal	$\tanh(\beta_0(x_i \cdot x_j) + \beta_0)$
Série de Fourier	$\prod_{k=1}^n K(x_k, x_{ik})$
Splines Lineares	$\sum_{i=1}^N \alpha_i K(x, x_i)$

A função kernel mais comumente utilizada é a função radial de base (RBF) (HAYKIN, 2001). Enquanto o produto interno kernel é uma medida de similaridade entre dois vetores, o kernel RBF é conceitualmente uma medida não-linear de similaridade. O ajuste do parâmetro de variância (σ^2) muda a largura da gaussiana e o grau da não-linearidade que pode ser modelada. Conforme σ^2 é aumentado o kernel força o modelo para uma solução linear (COGDILL; DARDENNE, 2004). A dimensionalidade do espaço (oculto) de características é feito propositalmente muito grande para a construção de uma superfície de decisão na forma de um hiperplano naquele espaço. Os parâmetros Gama (γ) e σ^2 devem ser sintonizados simultaneamente.

O parâmetro γ é específico para funções kernel polinomiais, RBF e sigmoide. O valor de γ pode desempenhar um papel importante no modelo MVS, pois sua variação pode alterar a precisão do modelo resultante. Desta forma, a utilização de validação cruzada pode auxiliar a encontrar o valor ideal de Gama.

O kernel RBF, conforme apresentado na Tabela 3, possui um parâmetro Gama (γ) que é equivalente a $\gamma = 1/2\sigma^2$ como pode se visto na Equação 22.

$$k(x, x') = \exp\left(-\frac{\|x_i - x_j\|^2}{2\sigma^2}\right) \quad (22)$$

O parâmetro γ controla a flexibilidade da função de kernel, valores pequenos de γ permitem ao classificador ajustar todos os rótulos havendo risco de sobre ajustamento (*overfitting*). Nesse caso o kernel da matriz se aproxima da matriz de identidade. Por outro lado, valores grandes de Gama reduzem o kernel para uma função constante, tornando impossível o processo de aprendizagem de qualquer classificador não-trivial (SHAWE-TAYLOR; CRISTIANINI, 2004).

Além do parâmetro γ do kernel RBF, conforme apresentado, outro parâmetro importante para as MVS é o parâmetro C, que controla a compensação dos erros cometidos na fase de treinamento, e a margem rígida, permitindo que alguns erros de classificação sejam cometidos. O parâmetro C é um parâmetro a ser escolhido pelo usuário, visto que quanto maior o seu valor, maior será a penalização associada aos erros cometidos. A constante C é conhecida como “parâmetro de margem” e estabelece a importância relativa das duas parcelas do lado direito da

igualdade da Equação (13) no processo de minimização. A minimização de $\|w\|^2$ resulta na maximização da margem, enquanto que a minimização da segunda parcela $(\sum_i^N \xi_i)$ resulta na minimização do erro de classificação.

O kernel RBF não linear mapeia amostras em um espaço dimensional superior, enquanto o kernel RBF, ao contrário do núcleo linear, pode tratar o caso em que a relação entre as etiquetas de classe e atributos não é linear. O kernel linear é um caso especial do kernel RBF, enquanto o kernel sigmóide se comporta como o kernel RBF para certos parâmetros e não é válido para outros.

O número de hiperparâmetros influencia a complexidade da seleção de modelos. O kernel poli tem mais hiperparâmetros do que o kernel RBF, logo o kernel RBF tem menos dificuldades numéricas.

Há algumas situações em que o kernel RBF não é adequado. Em particular, quando o número de recursos é muito grande, pode-se usar apenas o kernel linear.

A máquina de vetor de suporte fornece um método para controlar a complexidade do modelo independentemente da dimensionalidade. Em particular, o problema da complexidade do modelo é resolvido em um espaço de alta dimensionalidade usando um hiperplano penalizado definido no espaço (oculto) de características como a superfície de decisão; o resultado é um bom desempenho de decisão.

Mais importante que isso, usando um núcleo de um produto interno adequado, uma SVM calcula automaticamente todos os parâmetros importantes da rede relativos àquela escolha de núcleo. No caso de uma rede de função de base radial, o núcleo é uma função gaussiana. Para este método de implementação, o número de funções de base radial e seus centros e seus pesos são calculados automaticamente. Os centros das funções de base radial são definidos pelos vetores de suporte escolhidos pela estratégia de otimização quadrática. Os vetores de suporte são tipicamente uma fração do número total de exemplos que constituem a amostra de treinamento.

3 MATERIAIS E MÉTODOS

Neste capítulo, estão apresentadas as metodologias aplicadas para a resolução do trabalho e o material utilizado. O capítulo divide-se em seções, sendo elas: base de dados, seleções das variáveis independentes, ferramentas utilizadas, estimativa da capacidade de carga do solo com RLM, estimativa da capacidade de carga do solo com RNA, estimativa da capacidade de carga do solo com MVS, metodologia computacional e avaliação dos modelos.

Para desenvolver o presente trabalho foram utilizados dados de características físico-hídricas e físico-mecânicas do solo disponíveis na literatura.

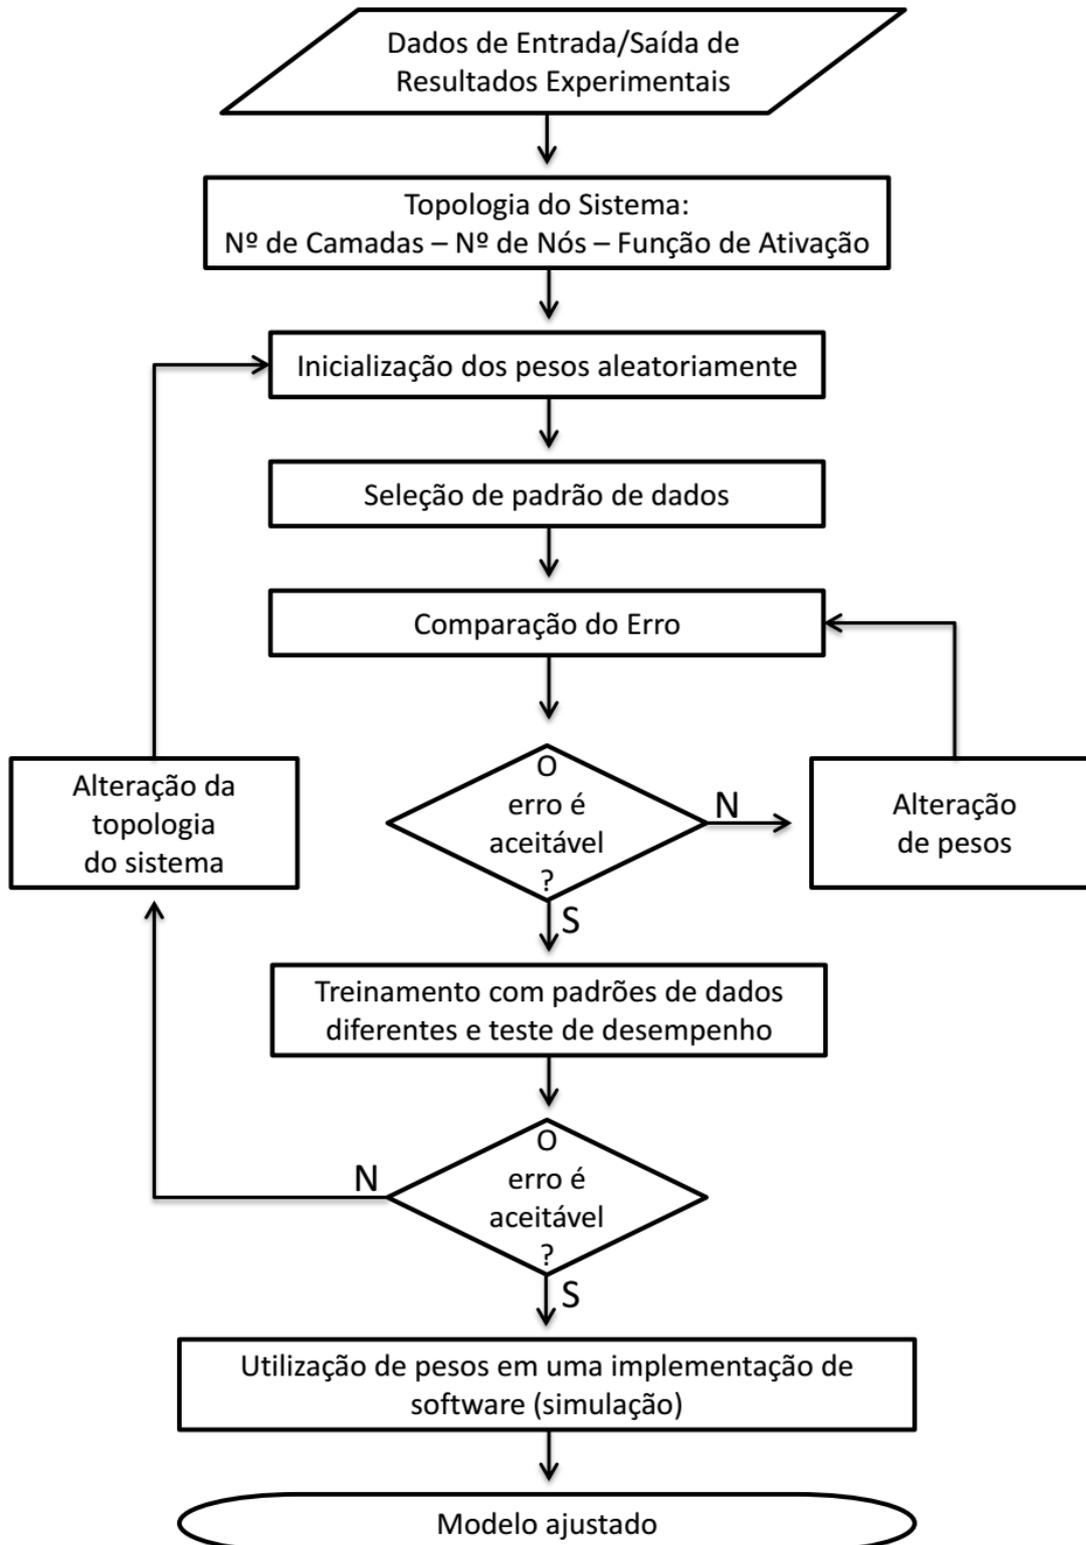
3.1 DESCRIÇÃO DO ESTUDO

O estudo baseou-se na necessidade de avaliar e equiparar diferentes opções metodológicas de estimativa da capacidade de suporte de carga do solo, tendo como finalidade principal buscar o método e as variáveis de entrada mais eficientes para obtenção da pressão de preconsolidação (σ_p) e da resistência à penetração (RP) do solo.

Mesmo com as metodologias comparadas neste estudo (RLM, RNA, e MVS) apresentando rotinas computacionais distintas, a estruturação básica necessária para a obtenção de resultados de estimativa significativos e com erros minimizados segue um determinado padrão que se assemelha independentemente do modelo que esteja sendo utilizado. Além disso, nesta estruturação é imprescindível que o banco de dados possua valores tanto de entradas quanto de saídas experimentais confiáveis, bem como grupos de dados distintos para o ajustamento ou treinamento (no caso de inteligência artificial) do modelo e para o teste ou simulação do modelo ajustado ou treinado.

Sendo assim o estudo se deu de acordo com as etapas descritas no fluxograma (Figura 17).

Figura 17 - Fluxograma da modelagem computacional



3.2 BASE DE DADOS

Para o desenvolvimento deste trabalho foi realizada uma pesquisa e investigação da literatura nacional e internacional de trabalhos (teses, dissertações, artigos, tcc's, etc.) de capacidade de suporte de carga do solo

A busca por esses trabalhos foi feita no meio digital, em bibliotecas digitais (Biblioteca brasileira de teses e dissertações, Portal domínio público), periódicos e sites de Universidades. Os dados foram organizados em planilha eletrônica (Microsoft Excel 2010) chamada "Banco de Dados", inicialmente sem a divisão das classes texturais, e posteriormente separando-se dados de mesma classe textural para promover comparações adicionais.

A partir dessas informações se pode abastecer os softwares de modelagem, com o objetivo de se estimar valores de pressão de preconsolidação (σ_p) e de resistência à penetração (RP) a partir de características do solo, utilizando as técnicas de RLM, RNA e MVS, podendo assim compará-las.

Os trabalhos dos quais o banco de dados foi abastecido são produção dos seguintes autores: Ajayi (2009;2009_2), Ajayi (2010), Angelotti Netto (2007), Arvidsson (2004), Beutler (2001), Blainiski (2008), Freddi (2007), Capurro (2005), Cavaliere (2009), Coralles (2005), Debiase (2008), Dias Junior et al. (2004), Flores et al. (2007), Fontanela (2008; 2012), Gubiani (2012), Gubiani et al. (2014), Julião (2009), Kaiser (2010), Kondo e Dias Junior (1999-2), Keller (2004), Lima (2004), Lima et al. (2004; 2005), Lima et al. (2013), Marasca (2010), Marcolin (2006), Martins et al. (2002), Martins (2012), Mazurana (2011), Mentges (2010), Mentges et al.(2013), Mosaddeghi et al. (2007), Oliveira et al. (2011), Pereira Junior et al. (2011), Rosa (2007), Rosa (2009), Salire et al. (1994), Sanchez (2012), Secco (2003), Severiano (2010), Silva et al. (2000; 2002), Silva et al.(2003; 2006), Silva (2003), Silva (2013), Stumpf (2011), Suzuki et al.(2008), Tavares (2011), Tormena et al. (2002), Veiga et al. (2007), Vogelmann et al. (2012), Werlang (2004).

3.3 SELEÇÃO DAS VARIÁVEIS NA CAMADA DE ENTRADA

Para a seleção das entradas foram compostos treze diferentes arranjos ou tratamentos (Tabela 4) sendo o primeiro composto por todas as variáveis de entrada e os seguintes foram estabelecidos retirando-se alguma ou algumas destas. Esses

modelos foram treinados, testados, e após foi verificado qual deles obteve o melhor desempenho. Foram escolhidas as seguintes variáveis de entrada para a formulação dos modelos: teores de Argila (Arg), Areia (Are) e Silte (Sil), Limite de Plasticidade (LP), Limite de liquidez (LL), Porosidade total (P_t), teor de Matéria orgânica (MO), densidade do solo (D_s), densidade de partícula (D_p) e Umidade volumétrica do solo (θ), tendo em vista que são parâmetros obtidos de forma mais fácil ou econômica, do que os indicadores que são o objetivo deste estudo: resistência à penetração (RP) e pressão de preconsolidação (σ_p).

Tabela 4 - Variáveis independentes de entrada nos modelos computacionais de estimativa de resistência à penetração (RP) e pressão de preconsolidação (σ_p).

Modelo	Variáveis									
	Arg	Sil	Are	LP	LL	D_p	P_t	MO	D_s	θ
M1	•	•	•	•	•	•	•	•	•	•
M2	•	•	•	•	•	•	•		•	•
M3	•	•	•			•	•	•	•	•
M4	•	•	•			•	•		•	•
M5	•	•	•			•			•	•
M6	•	•	•						•	•
M7	• +	•	•						•	•
M8	•	•	•						•	
M9	•	•	•							•
M10	• +	•	•						•	
M11	• +	•	•							•
M12	•	•	•							
M13									•	•

Fonte: Autor.

A criação de alguns modelos com esta variável (Argila+Silte) se deu em função de que é uma variável mais facilmente levantada do que ambas separadamente, além de onerar muito menos tempo para adquiri-la.

Além dos treze diferentes conjuntos de dados de entrada composto por classes texturais diversas, outros três conjuntos com classe textural distintas (Franco arenoso de uma única área produtiva sob diferentes manejos – FA1; Franco arenosos de diferentes localidades – FA2; e Muito argiloso de uma mesma propriedade exposto ao mesmo manejo – MA) foram utilizados com a finalidade de

comparar os métodos estudados aos métodos de Busscher (para estimativa da RP) e de Dias Jr. e Pierce (para estimativa da σ_p). As variáveis independentes destes conjuntos foram as mesmas de M13 (densidade do solo e umidade volumétrica).

Para as técnicas computacionais utilizadas, além das variáveis de entrada e dos tratamentos utilizados para simulação os valores das variáveis de saída medidas também foram importados para os softwares, visto que estes apresentam modelos matemáticos inspirados em organismos inteligentes e que adquirem conhecimento através da experiência, ou seja, de um treinamento.

Desta forma se pode verificar na Tabela 5 as variações entre os modelos de entrada (independentes), as variáveis de saída (dependentes) e métodos de modelagem empregados neste trabalho.

Tabela 5 - Nomenclatura dos modelos de entrada em cada metodologia aplicada

Modelo	Resistência à Penetração			Pressão de Preconsolidação		
	RLM	RNA	MVS	RLM	RNA	MVS
M1	RLM1-RP	RNA1-RP	MVS1-RP	RLM1- σ_p	RNA1- σ_p	MVS1- σ_p
M2	RLM2-RP	RNA2-RP	MVS2-RP	RLM2- σ_p	RNA2- σ_p	MVS2- σ_p
M3	RLM3-RP	RNA3-RP	MVS3-RP	RLM3- σ_p	RNA3- σ_p	MVS3- σ_p
M4	RLM4-RP	RNA4-RP	MVS4-RP	RLM4- σ_p	RNA4- σ_p	MVS4- σ_p
M5	RLM5-RP	RNA5-RP	MVS5-RP	RLM5- σ_p	RNA5- σ_p	MVS5- σ_p
M6	RLM6-RP	RNA6-RP	MVS6-RP	RLM6- σ_p	RNA6- σ_p	MVS6- σ_p
M7	RLM7-RP	RNA7-RP	MVS7-RP	RLM7- σ_p	RNA7- σ_p	MVS7- σ_p
M8	RLM8-RP	RNA8-RP	MVS8-RP	RLM8- σ_p	RNA8- σ_p	MVS8- σ_p
M9	RLM9-RP	RNA9-RP	MVS9-RP	RLM9- σ_p	RNA9- σ_p	MVS9- σ_p
M10	RLM10-RP	RNA10-RP	MVS10-RP	RLM10- σ_p	RNA10- σ_p	MVS10- σ_p
M11	RLM11-RP	RNA11-RP	MVS11-RP	RLM11- σ_p	RNA11- σ_p	MVS11- σ_p
M12	RLM12-RP	RNA12-RP	MVS12-RP	RLM12- σ_p	RNA12- σ_p	MVS12- σ_p
M13	RLM13-RP	RNA13-RP	MVS13-RP	RLM13- σ_p	RNA13- σ_p	MVS13- σ_p

Fonte: Autor.

Como para cada arquitetura das redes neurais (RNA), os dados foram divididos aleatoriamente em cerca de 75 a 80% para treinamento e 20 a 25 % para validação da mesma, seguindo indicação de NAGAOKA et al. (2005), os mesmos grupos de dados foram utilizados para geração das funções com regressão linear múltipla (RLM) e suas respectivas validações, como para o treinamento e simulação nas máquinas de vetores de suporte (MVS), conforme Tabela 6.

Tabela 6 - Número de amostras utilizadas para obtenção da resistência à penetração (RP) e pressão de preconsolidação (σ_p)

Modelo	Resistência à Penetração		Pressão de Preconsolidação	
	Nº de Amostras Geração	Nº de Amostras Validação	Nº de Amostras Geração	Nº de Amostras Validação
M1	62	20	156	49
M2	62	20	194	65
M3	252	75	291	77
M4	935	187	627	165
M5	935	187	627	165
M6	1057	223	687	183
M7	1057	223	687	183
M8	1084	232	714	191
M9	1057	223	687	183
M10	1084	232	714	191
M11	1057	223	687	183
M12	1102	238	724	196
M13	1061	224	687	183

Fonte: Autor

Com o banco de dados tabulado foi possível verificar sua variabilidade (Tabelas 7 e 8), visto que o mesmo é composto de amostras de dados amostrais de trabalhos desenvolvidos em diversas regiões, sob diferentes culturas e manejos.

Tabela 7 - Valores máximos, mínimos, médios, desvio padrão e coeficiente de variação (CV) das variáveis utilizadas nos modelos de Resistência à Penetração (RP) do banco de dados geral

Variáveis	Máximo	Mínimo	Média	Desvio Padrão	CV (%)
Areia (%)	94,00	1,00	31,18	24,16	77,50
Silte (%)	48,30	0,40	20,90	7,70	36,85
Argila (%)	78,80	4,00	47,91	21,38	44,62
Ds (g cm ⁻³)	1,94	0,83	1,35	0,19	14,28
Dp (g cm ⁻³)	3,59	1,45	2,62	0,24	9,15
Pt (cm ³ .cm ⁻³)	0,68	0,24	0,48	0,08	17,57
M.O. (g.kg ⁻¹)	76,00	0,20	18,35	13,42	73,14
θ (cm ³ /cm ³)	0,60	0,03	0,30	0,09	29,60
Limite de Liquidez	0,44	0,20	0,39	0,07	17,94
Limite de Plasticidade	0,31	0,16	0,28	0,04	14,41
RP (Mpa)	40,30	0,12	2,44	1,68	69,14

Fonte: Autor

Tabela 8 - Valores máximos, mínimos, médios, desvio padrão e coeficiente de variação (CV) das variáveis utilizadas nos modelos de Pressão de Preconsolidação (σ_p) do banco de dados geral

Variáveis	Máximo	Mínimo	Média	Desvio Padrao	CV (%)
Areia (%)	90,60	1,00	30,80	23,74	77,09
Silte (%)	81,20	2,00	29,44	19,87	67,51
Argila (%)	86,30	0,30	39,66	20,44	51,54
Ds (g.cm ⁻³)	1,94	0,71	1,36	0,21	15,10
Dp (g.cm ⁻³)	3,66	2,28	2,66	0,15	5,45
Pt (cm ³ .cm ⁻³)	0,69	0,25	0,49	0,08	16,15
M.O. (g.kg ⁻¹)	68,90	0,00	12,82	11,71	91,34
θ (cm ³ .cm ⁻³)	0,60	0,03	0,33	0,12	35,88
Limite de Liquidez	1,00	0,18	0,37	0,12	31,95
Limite de Plasticidade	1,00	0,13	0,27	0,13	47,24
σ_P (kpa)	528,00	11,00	158,39	95,14	60,07

Fonte: Autor

3.4 FERRAMENTAS UTILIZADAS

Para elaboração do trabalho foi necessário utilizar algumas ferramentas computacionais. Inicialmente, utilizou-se o Microsoft Excel 2010[®] para armazenamento e organização dos dados.

Para a estimativa dos parâmetros de capacidade de suporte de carga do solo através de RLM, RNA e MVS foram utilizados, respectivamente os *softwares* IBM-SPSS 20.0.[®], Matlab R2008b[®] e RapidMiner 5[®]. Cabe informar que dentre os utilizados o RapidMiner é o único software livre e possui uma interface gráfica bastante intuitiva, de forma a propiciar um maior acesso aos usuários.

Os três softwares utilizados são capazes de importar os dados diretamente do Microsoft Excel[®]. Entretanto, como a versão do Matlab é anterior à versão do Excel, e o número de colunas necessária para planilha de entrada de dados no modelo RNA é superior ao que a versão do Excel anterior a 2008 comporta, necessitou-se converter os arquivos de entrada no Matlab de Excel (.xlsx) para arquivo de dados (.csv)

3.5 ESTIMATIVA DA CAPACIDADE DE CARGA DO SOLO UTILIZANDO RLM

A partir dos valores de pressão de preconsolidação (σ_p) e de resistência à penetração (RP) (variáveis dependentes) e das variáveis independentes (Tabela 4) no banco de dados obtido, foram feitas análises de regressão múltipla para a obtenção das funções de pedotransferência usando a opção “*stepwise*” do *software IBM-SPSS 20.0*.

O programa computacional selecionou as variáveis que entraram nas equações de regressão, estimando-se os parâmetros para cada uma das variáveis independentes incluídas no modelo e também uma constante a ser somada a este. Desta forma, ajustou-se um modelo matemático para a estimativa dos parâmetros modelados, no caso a pressão de preconsolidação e a resistência à penetração, gerados para cada arquitetura de modelo, com a utilização dos dados destinados a validação, utilizando-se como critério de escolha o melhor coeficiente de correlação (R^2).

3.6 ESTIMATIVA DA CAPACIDADE DE CARGA DO SOLO UTILIZANDO RNA

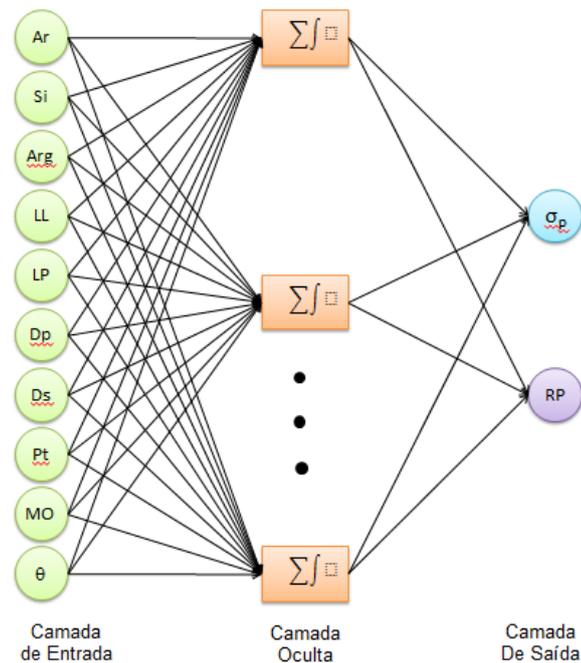
A partir das variáveis independentes (Tabela 4) e dos valores de pressão de preconsolidação (σ_p) e de resistência à penetração (RP) (variáveis dependentes) foram geradas funções de pedotransferência para as treze diferentes combinações ou modelos de dados de entrada, de forma a buscar a melhor estimativa e quais as propriedades do solo são mais significativas para esta estimativa.

3.6.1 Número de camadas escondidas e número de neurônios das RNA

A arquitetura da rede neural utilizada neste trabalho foi composta de uma camada de entrada, uma camada escondida e uma camada de saída (Figura 18), visto que bons resultados foram obtidos para estimativa de resistência do solo à penetração (SANTOS et al., 2012) e coesão e ângulo de atrito interno do solo, sendo ambos também indicadores de capacidade de carga do solo (BRAGA, 2014).

Para uma mesma arquitetura foram utilizadas diferentes topologias, isto é, foram realizadas variações nos neurônios da camada de entrada (variáveis independentes). Também foram feitas variações nos neurônios da camada oculta, e por último foram feitas variações nos neurônios de saída (variáveis dependentes).

Figura 18 - Arquitetura da rede neural utilizada



Fonte: Autor

Como dito anteriormente, apesar da modelagem por redes neurais permitir obter-se mais de um neurônio (mais de uma variável dependente) na camada de saída, foram analisadas apenas duas formas de composição do número de neurônios nessa camada: 1) um neurônio (pressão de preconstrução); e 2) um neurônio (resistência à penetração), em virtude da escassez de dados que alimentassem os modelos com as duas saídas simultâneas. Em relação a camada escondida, foram testadas variações na quantidade de neurônios, utilizando-se 10, 20, 30, 40 e 50 neurônios, conforme Braga (2014) a fim de verificar qual topologia gerou os melhores resultados.

3.6.2 Definição do treinamento da rede neural e avaliação do desempenho

O treinamento das redes neurais artificiais multicamadas foi realizado com o módulo Neural Network Toolbox, componente do *software* Matlab (versão R2008b).

Esse módulo tem implantado internamente como algoritmo de treinamento o *backpropagation* e como rotina de otimização a de Levenberg-Marquadt. A regra de treinamento utilizada pelo módulo é o aprendizado por correção de erro.

O treinamento foi realizado variando as variáveis de entrada e o número de neurônios na camada escondida. As variáveis independentes utilizadas nas RNA foram descritas na Tabela 4. Como os pesos são elementos iniciados com valores aleatórios, para cada treinamento se obtiveram valores diferentes.

Cada rede foi treinada 3, 4, 5, 6, 7, 8, 9, 10, 13, 15, 17, 19, 25 e 30 vezes, visto que segundo Soares (2013) não foram encontradas diferenças expressivas ao se utilizar grandes números de treinamentos. Após a realização dos treinamentos foi escolhida como melhor resultado aquela com o melhor coeficiente de correlação (R^2) entre os dados obtidos na literatura destinados a validação e os dados estimados pela simulação da Rede Neural Artificial.

3.7 ESTIMATIVA DA CAPACIDADE DE CARGA DO SOLO UTILIZANDO MVS

Assim como foi realizado com a RLM e a RNA, a partir das variáveis de entrada (Tabela 4) e dos valores de pressão de preconsolidação (σ_p) e de resistência à penetração (RP) (variáveis dependentes) foram geradas funções de pedotransferência para as treze diferentes combinações ou modelos de dados de entrada, de forma a buscar a melhor estimativa e quais as propriedades do solo são mais significativas para esta estimativa na modelagem através das MVS.

3.7.1 Definição da função kernel e dos parâmetros de entrada da MVS

O treinamento foi realizado no *software* RapidMiner5, selecionando-se para o tipo de MVS a opção epsilon-SVR¹, de forma a variar as entradas (Tabela 4), o tipo de função kernel (Tabela 3) e os parâmetros γ e C .

Cada modelo de entrada foi treinado com funções kernel dos tipos: linear; polinomial (de 2º e 3º graus); RBF (*Radial Basis Function*); e sigmoidal. Sendo que para cada uma das funções kernel, também foram testados o parâmetro C com valores de 0, 50, 100 e 150.

O parâmetro γ também foi testado para cada uma das variações de C e da função kernel, exceto da função kernel linear que não apresenta o γ em sua formulação.

Tendo em vista que as variações do parâmetro γ geram muita influência no

¹ epsilon-SVR. Especifica o tubo epsilon dentro do qual nenhuma penalidade é associada na função de perda de treinamento com pontos previstos dentro de um epsilon distância do valor real.

resultado final os valores foram sendo ajustados a cada simulação de forma a se alcançar os melhores resultados para cada um dos treze modelos de entrada de dados. Para o ajuste do parâmetro γ foi utilizado valor de partida igual a 0 de forma a incrementá-lo em intervalos de 5 enquanto o coeficiente de determinação (R^2) permanecesse aumentando, admitindo-se como ponto de parada o momento ao qual o coeficiente de determinação (R^2) diminui. Desta forma buscou-se o valor de γ mais eficiente dentro dos dois últimos intervalos.

3.8 ANÁLISE DE DADOS

Com base nos valores de pressão de preconsolidação e resistência à penetração estimados, foram ajustadas equações de regressão linear, de forma a serem analisadas graficamente pela relação 1:1 onde a variável dependente foram os respectivos valores obtidos do banco de dados, e variável independente os valores estimados pelos métodos em estudo (RLM, RNA, MVS).

Também foram avaliados os valores estimados de RP pelo modelo de Busscher (1990), comparando-o aos métodos em estudo, para os dados de entrada de M4, M5, M6 e M13, além de comparação dos métodos em grupos de dados separados por classes texturais de solo (muito argiloso de um mesmo local sob um único manejo; franco arenoso de vários locais; e franco arenoso de um mesmo local sob diferentes manejos) visto que o modelo de Busscher foi desenvolvido para estimar dados em condições de textura semelhantes.

Os valores estimados de pressão de preconsolidação foram comparados aos obtidos pelo método de Dias Junior e Pierce (1995).

As análises comparativas foram realizadas usando o índice de correlação (r), concordância (c) (WILLMOTT et al., 1981) e desempenho (id) (Equação 23) sugeridos por Camargo e Sentelhas (1997) (Tabela 9) onde :

$$id = r \cdot c \quad (23)$$

O coeficiente de correlação (r) pode variar de 0 a +1 ou 0 a -1, e foi classificado de acordo com Silva e Barros Filho (2003). Os valores do coeficiente (c) variam de zero, para nenhuma concordância, a 1, para concordância perfeita, e é dado pela Equação 24:

$$c = 1 - \frac{\sum_{i=1}^n (P_i - O_i)^2}{\sum_{i=1}^n (|P_i - O| + |O_i - O|)^2} \quad (24)$$

Onde P_i é o valor estimado, O_i o valor observado e O a média dos valores observados.

O coeficiente r é dado pela Equação 25 a seguir:

$$r = \frac{\sum_{i=1}^n (P_i - P)(O_i - O)}{\sqrt{\{[\sum_{i=1}^n (P_i - P)^2][\sum_{i=1}^n (O_i - O)^2]\}}} \quad (25)$$

Onde P_i é o valor estimado, P a média dos valores estimados, O_i o valor observado e O a média dos valores observados.

O critério adotado para interpretar o desempenho dos métodos pelo índice “ c ” se apresenta na tabela 9 a seguir:

Tabela 9 - Classificação do índice de desempenho (id)

Classes	Valor de id	Desempenho
1	> 0,85	Ótimo
2	0,76 a 0,85	Muito Bom
3	0,66 a 0,75	Bom
4	0,61 a 0,65	Regular
5	0,51 a 0,60	Fraco
6	0,41 a 0,50	Muito Fraco
7	< 0,41	Péssimo

Fonte: Autor (Adaptado de WILLMOTT et al., 1981)

4 RESULTADOS E DISCUSSÃO

Este capítulo apresenta valores estimados de resistência à penetração (RP) e de pressão de preconsolidação (σ_p) mediante apresentação de tabelas e gráficos. Os resultados foram agrupados em tabelas comparativas, permitindo realizar avaliações da aplicação das três diferentes metodologias, bem como comparações entre estes e métodos conceituados descritos na literatura.

Na sequência estão expostos os resultados obtidos para os fatores analisados sob combinações de treze diferentes conjuntos de dados de entrada, cinco variações de números de neurônios na camada escondida (RNA), cinco diferentes funções kernel (MVS), quatro variações do parâmetro C (MVS), e pelo menos cinco variações do parâmetro γ (MVS).

4.1 VALORES ESTIMADOS POR REGRESSÃO LINEAR MÚLTIPLA (RLM)

Esta seção apresenta os resultados estimados das propriedades físico-mecânicas que se caracterizam por estimar a capacidade de suporte de carga do solo agrícola (resistência à penetração e pressão de preconsolidação) obtidos para cada um dos treze conjuntos de dados sem distinção de classe textural, e outros três conjuntos com classe textural distintas, através de Regressão Linear Múltipla (RLM).

4.1.1 Correlação entre variáveis independentes e os indicadores de capacidade de suporte de carga do solo

Os valores obtidos para indicar as correlações entre as propriedades físico-hídricas do solo (variáveis independentes ou de entrada nos modelos) e os indicadores resistência à penetração e pressão de preconsolidação (variáveis dependentes) são apresentados na Tabela 10. Segundo Mazurana (2011) estas propriedades representam os fatores internos que regem a capacidade de suporte de carga dos solos, e desta forma, suas correlações com as variáveis dependentes indicam o quanto cada uma destas propriedades exerce influência, de forma linear, na resistência à penetração (RP) e na pressão de preconsolidação (σ_p).

Tabela 10 - Coeficiente de correlação (r) entre as variáveis independentes e dependentes para as Regressões Lineares Múltiplas

(continua)

Modelo	Variáveis Independentes	Variáveis Dependentes	
		RP (MPa)	σ_p (kPa)
RLM1	Areia	-0,209	-0,160
	Silte	-0,146	-0,127
	Argila	0,307	0,339
	D _s	0,539	0,127
	D _p	0,385	0,381
	P _t	-0,349	0,007
	MO	-0,005	-0,381
	θ	0,291	-0,134
	LL	0,185	0,122
	LP	0,031	0,099
RLM2	Areia	-0,209	-0,229
	Silte	-0,146	-0,091
	Argila	0,307	0,378
	D _s	0,539	0,055
	D _p	0,385	0,139
	P _t	-0,349	0,032
	θ	0,291	-0,062
	LL	0,185	0,130
	LP	0,031	0,003
	RLM3	Areia	0,102
Silte		-0,370	-0,095
Argila		0,023	0,383
D _s		0,383	0,039
D _p		0,058	0,300
P _t		-0,292	0,056
Mo		0,069	-0,379
θ		-0,121	0,043
RLM4		Areia	-0,023
	Silte	-0,114	-0,067
	Argila	0,065	0,213
	D _s	0,19	-0,097
	D _p	-0,16	0,113
	P _t	-0,291	0,120
	θ	-0,023	-0,172
RLM5	Areia	-0,023	-0,141
	Silte	-0,114	-0,067
	Argila	0,065	0,213
	D _s	0,19	-0,097
	D _p	-0,16	0,113
	θ	-0,023	-0,172

Tabela 10 – Coeficientes de correlação (r) entre as variáveis independentes e dependentes para as Regressões Lineares Múltiplas

(continuação)

Modelo	Variáveis Independentes	Variáveis Dependentes	
		RP (MPa)	σ_p (kPa)
RLM6	Areia	-0,056	-0,162
	Silte	-0,072	-0,058
	Argila	0,089	0,240
	D _s	0,161	-0,132
	θ	-0,048	-0,130
RLM7	Areia	-0,056	-0,162
	Silte + Argila	0,056	0,159
	D _s	0,161	-0,132
	θ	-0,048	-0,130
RLM8	Areia	-0,058	-0,161
	Silte	-0,074	-0,049
	Argila	0,092	0,229
	D _s	0,160	-0,125
RLM9	Areia	-0,056	-0,162
	Silte	-0,072	-0,058
	Argila	0,089	0,240
	θ	-0,048	-0,130
RLM10	Areia	-0,058	-0,161
	Silte + Argila	0,058	0,158
	D _s	0,16	-0,125
RLM11	Areia	-0,056	-0,162
	Silte + Argila	0,056	0,159
	θ	-0,048	-0,130
RLM12	Areia	0,012	-0,136
	Silte	-0,116	-0,059
	Argila	0,027	0,213
RLM13	D _s	0,162	-0,132
	θ	-0,047	-0,130
RLM-FA1	D _s	0,648	-
	θ	0,314	-
RLM-FA2	D _s	0,185	-
	θ	0,003	-
RLM-MA	D _s	0,659	-
	θ	-0,028	-

Fonte: Autor

Areia (%); Silte (%); Argila (%); D_s - densidade do solo (g.cm⁻³); D_p - densidade de partícula (g.cm⁻³); P_t - Porosidade total (cm³. cm⁻³); MO - teor de Matéria orgânica (%); θ - Umidade volumétrica do solo (cm³. cm⁻³); LP - Limite de Plasticidade; LL - Limite de liquidez.

O coeficiente de correlação de Pearson (r) indica a relação linear (força e direção) entre as duas variáveis e pode variar de 0 a 1 ou 0 a -1, sendo que 0 (zero) indica que não há relação linear, 1 indica uma relação linear perfeita e -1 indica uma

relação linear perfeita porém inversa, ou seja, enquanto uma das variáveis cresce a outra decresce (SILVA ; BARROS FILHO, 2003). Sendo assim, quanto mais próximo os valores de r estiverem de 1 e/ou -1, mais forte é a associação linear entre as duas variáveis.

Observou-se que tanto para RLM1 quanto pra RLM2, as correlações positivas entre as variáveis independentes (Argila, D_s , D_p , θ , LL e LP) e a resistência à penetração (RP) foram as mesmas. O mesmo ocorreu para as correlações negativas entre as variáveis de entrada (Areia, Silte, P_t e MO), sendo que as variáveis com maior e menor correlação positiva foram, respectivamente, a densidade do solo (0,539) e o limite de plasticidade (0,031), enquanto as variáveis que mais e menos se correlacionaram negativamente, ou seja, inversamente à RP foram porosidade total (-0,349) e o teor de matéria orgânica (-0,005). A boa correlação entre a resistência à penetração e a densidade do solo era um resultado esperado, visto os inúmeros trabalhos onde ambos são correlacionados em regressões na forma linear simples (BLAINSKI, 2008; GUBIANI, 2012; KAISER, 2010; LIMA, 2007; PEREIRA JUNIOR, 2011; SANTOS,2012).

Já para a pressão de preconsolidação (σ_p) o comportamento foi diferente entre RLM1 e RLM2, visto a influência que o teor de matéria orgânica (MO) demonstrou exercer sobre a σ_p . Desta forma, no modelo RLM1- σ_p a maior correlação positiva ocorreu com a densidade de partícula (0,381) enquanto a maior correlação negativa se deu com o Teor de matéria orgânica (-0,381). Este resultado reforça o descrito por Fontanela (2012) onde afirma que a compactação do solo, principalmente pelo sistema de semeadura direta, pode ser evitada ou reduzida por meio do incremento e manutenção de resíduos orgânicos na superfície do solo, a fim de aumentar seu conteúdo de matéria orgânica, e também se assemelha aos resultados encontrados por Mazurana (2011) para solos em condições naturais. Já as variáveis de entrada (independentes) que menos se correlacionaram com a pressão de preconsolidação foram a porosidade total (0,007) e o limite de plasticidade (0,099), corroborando com resultados obtidos por Arvidsson (2004) onde este obteve uma correlação simples de entre pressão de preconsolidação e porosidade total de 0,04 e R^2 de 0,0017.

O modelo RLM2- σ_p , por não possuir o MO como variável de entrada, apresentou maior correlação positiva como teor de argila (0,378), seguida da maior correlação negativa com o teor de areia (-0,229), o que reforça os resultados

encontrados por Veenhof e McBride (1996) que obtiveram maior pressão de preconsolidação no subsolo com alto teor de argila.

Cabe ressaltar que no modelo RLM1, ao qual utiliza-se do maior número de variáveis independentes, as variáveis que apresentaram comportamento inverso em comparação a RP e σ_p foram porosidade total (P_t) que se relaciona negativamente com resistência à penetração e positivamente com a pressão de preconsolidação, e a umidade volumétrica (θ) que tem correlação positiva com a RP e negativa com a σ_p .

Na RLM3 as variáveis que melhor se correlacionaram com a RP foram a densidade do solo (0,383) seguido do silte (-0,370) enquanto que as melhores correlações com a pressão de preconsolidação (σ_p) foram com os teores de argila (0,383) e de matéria orgânica (-0,349).

O modelo RLM4 apresentou valores de r bem inferiores aos modelos anteriores, tanto para RP quanto para σ_p , tendo os maiores valores (em módulo) gerados pela porosidade total (-0,291) e pelo teor de argila (0,213) em relação à resistência à penetração e a pressão de preconsolidação, respectivamente.

Os valores do coeficiente de correlação (r) referentes ao modelo RLM5 não apresentaram diferenças de RLM4 em relação a σ_p , visto que, como já abordado anteriormente, a porosidade total (P_t) é das variáveis de entrada a que menos se correlaciona com a pressão de preconsolidação, e a utilização desta variável é o que diferencia RLM4 de RLM5. Entretanto, quando as correlações de RLM5 são para a RP , a ausência da variável P_t tem grande influência, deixando o modelo com seu maior coeficiente de correlação igual 0,19 referente a densidade do solo.

Tratando-se da RP os modelos RLM6 e RLM7 apresentam valores de correlações baixos e semelhantes sendo que em ambos a variável que melhor se correlacionou foi a densidade do solo (D_s) como valor de 0,161 em ambos os modelos. Os valores semelhantes entre esses modelos esta no fato de que a diferença é apenas que em RLM6 as partículas finas de solo (Argila e Silte) estão separadas, sendo cada uma delas uma variável de entrada, enquanto em RLM7 a soma de ambas representa apenas uma das variáveis de entrada (Argila + Silte).

Em relação a pressão de preconsolidação (σ_p) existem diferenças entre os modelos RLM6 e RLM7. Pode-se notar que em RLM6 as melhores correlações são com a argila (0,240) positivamente, seguida da areia (-0,162) negativamente. Já em RLM7, devido a associação argila + silte, a variável que mais se correlaciona a σ_p passa a ser a areia (-0,162), seguida da soma argila + silte (0,159).

O modelo RLM8 é composto apenas por textura e densidade do solo tendo, em relação à RP , como correlações positivas a argila (0,092) e a densidade do solo (0,160 – maior valor), e correlações negativas a areia (-0,058) e o silte (-0,074). Em função da σ_p apenas a argila (0,229 – maior valor) se correlacionou positivamente, enquanto areia (-0,161), silte (-0,049 – menor valor) e densidade do solo (-0,125) se correlacionaram negativamente. Além de Veenhof e McBride (1996), Debiase (2008) também cita que o teor de argila é um dos principais atributos do solo que afetam a pressão de preconsolidação.

A textura e a umidade volumétrica do solo são as variáveis que compõe a RLM9, sendo a argila a variável independente que melhor se correlaciona tanto com a resistência a penetração (RP) quanto com a pressão de preconsolidação (σ_p), com respectivos valores de 0,089 e 0,240, além de ser a única das variáveis independentes deste modelo (RLM9) a se correlacionar positivamente com as variáveis dependentes.

Os modelos RLM 10 e RLM11 se assemelham aos modelos RLM8 e RLM9, respectivamente, diferenciando-se apenas pela associação das classes granulométricas argila e silte (Argila+Silte). Desta forma no RLM10 o maior valor de correlação com a (RP) continuou, semelhante a RLM8, sendo a densidade do solo (0,160). Entretanto a correlação com σ_p sofreu modificações em relação a RLM8, pois não havendo a variável Argila, a melhor correlação passou a ser com a variável Areia, porém com valor negativo igual a -0,161, ficando a correlação positiva com a variável Argila+Silte (0,158). Por conseguinte, RLM11- σ_p ficou com os valores muito próximos a RLM10- σ_p , e teve o valor r para areia de -0,162 e para a soma de argila e silte igual a 0,159. Já em RLM11- RP , em virtude da baixa correlação com a umidade volumétrica (-0,048), a textura foi responsável pelas melhores, porém ainda assim baixas correlações do teor de areia (-0,056) e da soma de argila e silte (0,056).

As variáveis independentes que compõe a RLM12 são apenas areia, silte e argila. O maior valor de correlação de RLM12- RP foi para silte (-0,116), seguido de argila (0,027) e areia (0,012). Como já citado anteriormente, a argila é um dos atributos do solo que mais exercem influência na σ_p o que justifica que o modelo RLM12- σ_p apresente a melhor correlação com a argila (0,213).

A RLM13 tem como variáveis de entrada a densidade do solo (D_s) e a umidade volumétrica (θ). Os valores de r para RP foram 0,162 para D_s e -0,047 para θ , enquanto que para σ_p foram, respectivamente, -0,132 e -0,130.

Apesar de algumas correlações apresentarem relação com a bibliografia os valores abaixo de 50%, na quase totalidade dos dados, implicam em apontar que, apesar de a maioria das variáveis independentes serem consideradas influentes nas variáveis dependentes RP e σ_p , as relações entre estas não são lineares.

4.1.2 Estimativa dos indicadores de capacidade de suporte de carga – RLM1

A Tabela 11 apresenta as FPTs geradas para a estimativa dos parâmetros resistência à penetração (RP) e pressão de preconsolidação do solo (σ_p) com seus respectivos coeficientes de determinação (R^2).

Observa-se (Tabela 11) que as variáveis com contribuição significativa para a FPT de estimativa da RP foram densidade do solo e densidade de partícula, sendo que a D_s foi a variável que apresentou maior contribuição ao modelo, visto que esta apresentou valor de R^2 parcial (0,291). Esse valor está de acordo com o resultado da correlação apresentado na Tabela 10, onde a D_s teve correlação superior com a resistência à penetração, sendo que com exceção a D_p as demais variáveis independentes não foram significativas para a FPT.

Tabela 11 - Coeficientes das equações de regressão linear múltipla e de determinação para estimativa da resistência à penetração e da pressão de preconsolidação para a RLM 1

Variáveis	RP		σ_p	
	Coeficiente	R^2 Parcial	Coeficiente	R^2 Parcial
Constante	-17,190		-318,329	
Areia	ns		ns	
Silte	ns		ns	
Argila	ns		ns	
D_s	3,728	0,291	290,291	0,089
D_p	4,959	0,200	23,050	0,145
P_t	ns		ns	
MO	ns		-4,696	0,067
θ	ns		-773,517	0,067
LL	ns		934,118	0,071
LP	ns		ns	
R^2 - Modelo		0,491		0,438
R^2 - Validação		0,458		0,429

Fonte: Autor

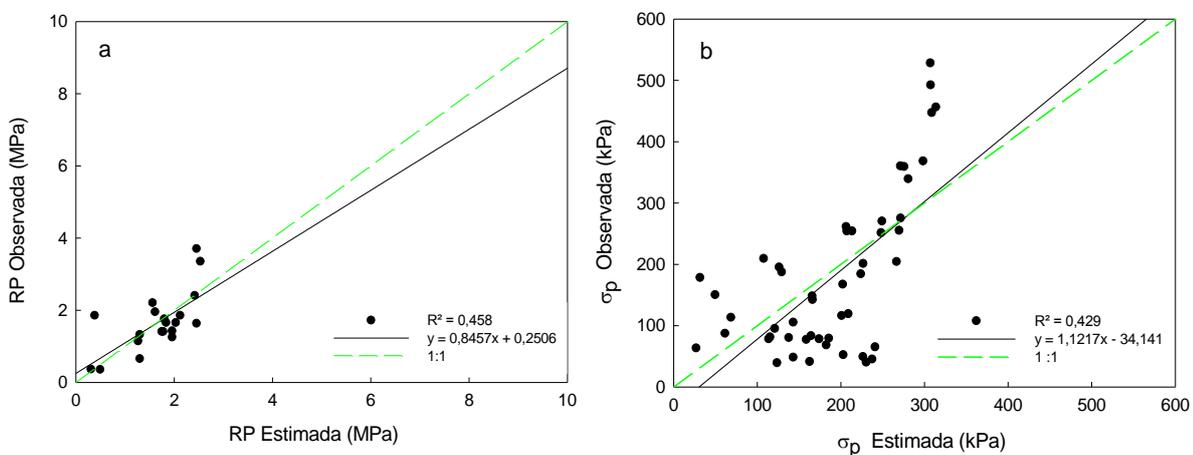
Areia (%); Silte (%); Argila (%); D_s - densidade do solo ($g.cm^{-3}$); D_p - densidade de partícula ($g.cm^{-3}$); P_t - Porosidade total ($cm^3.cm^{-3}$); MO - teor de Matéria orgânica (%); θ - Umidade volumétrica do solo ($cm^3.cm^{-3}$); LP - Limite de Plasticidade; LL - Limite de liquidez; ns – não significativo a 5% de probabilidade de erro.

Diferente da resistência à penetração do solo (RP), que obteve grau de significância apenas de duas variáveis independentes a pressão de preconsolidação do solo (σ_p) obteve como significativas para sua FPT as variáveis independentes densidade do solo (D_s), densidade de partícula (D_p), teor de matéria orgânica (MO), umidade volumétrica (θ) e limite de liquidez (LL), ainda assim com baixos valores de R^2 parcial e do modelo (0,438).

Entretanto, mesmo com a correlação e o R^2 mostrando haver maior relação entre D_s e RP, o valores de R^2 obtido pelo modelo (0,491) e pela validação (0,458) inferiores a 50% demonstram que o modelo gerado a partir de todo o banco de dados não foi eficiente para estimativa da resistência à penetração do solo (RP), o que pode ser comprovado pela grande dispersão dos pontos na comparação dos dados medidos e estimados pelo modelo (Figura 19a), além de reforçar os resultados obtidos por Kaiser (2010) onde se observou que a variação da densidade do solo não gera um incremento na resistência do solo maior do que o gerado pela variação de umidade.

Mesmo com um número maior de variáveis significativas que RLM1-RP, o modelo de estimativa da pressão de preconsolidação (RLM1- σ_p) apresentou uma dispersão ainda maior (Figura 19-b) que o modelo de estimativa de resistência à penetração, o que sugere a não linearidade entre as variáveis de entrada (independentes) e a pressão de preconsolidação (σ_p).

Figura 19 - Representação gráfica dos valores de RP e σ_p observados na literatura em relação aos estimados por regressão linear múltipla no modelo RLM1



4.1.3 Estimativa dos indicadores de capacidade de suporte de carga – RLM2

As FPTs geradas a partir do modelo RLM2 para a estimativa dos parâmetros resistência à penetração (RP) e pressão de preconsolidação do solo (σ_p) com seus respectivos coeficientes de determinação (R^2) são apresentadas na Tabela 12.

Pode-se notar que modelo RLM2 quando utilizado para estimar a RP não apresentou diferenças em relação a RLM1, visto que a variável teor de matéria orgânica (MO) não foi significativa ao modelo, o que de certa forma vai de encontro com as FTPs obtidas por Ribon e Tavares Filho (2008) onde MO foi significativa para a classe textural em estudo e para umidades gravimétricas inferiores a $0,2 \text{ kgkg}^{-1}$. Sendo a ausência desta variável a diferença entre RLM1 e RLM2, os coeficientes em ambos os modelos são iguais. Todavia, para a estimativa da pressão de preconsolidação a ausência da variável MO prejudicou o desempenho do modelo, que obteve R^2 igual a 0,250.

Tabela 12 - Coeficientes das equações de regressão linear múltipla e de determinação para estimativa da resistência à penetração e da pressão de preconsolidação para a RLM 2

Variáveis	RP		σ_p	
	Coeficiente	R ² Parcial	Coeficiente	R ² Parcial
Constante	-17,190		254,902	
Areia	ns		ns	
Silte	ns		2,020	0,026
Argila	ns		4,722	0,143
D _s	3,728	0,291	ns	
D _p	4,959	0,200	ns	
P _t	ns		-391,849	0,051
θ	ns		-443,851	0,03
LL	ns		ns	
LP	ns		ns	
R ² - Modelo		0,491		0,250
R ² - Validação		0,458		0,1954

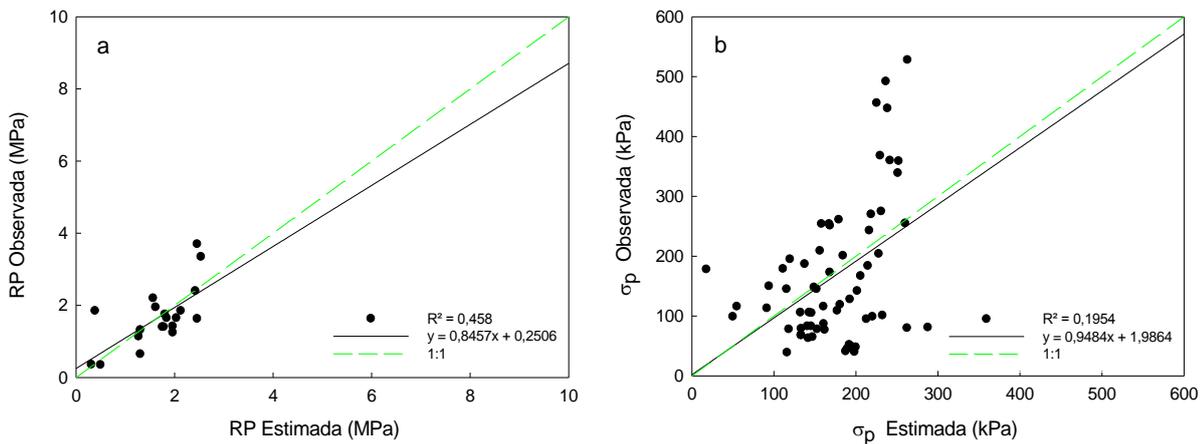
Fonte: Autor

Areia (%); Silte (%); Argila (%); D_s - densidade do solo (g.cm^{-3}); D_p - densidade de partícula (g.cm^{-3}); P_t - Porosidade total ($\text{cm}^3 \cdot \text{cm}^{-3}$); θ - Umidade volumétrica do solo ($\text{cm}^3 \cdot \text{cm}^{-3}$); LP - Limite de Plasticidade; LL - Limite de liquidez; ns – não significativo a 5% de probabilidade de erro.

Visualizando a Figura 20 se pode notar a igualdade das FPTs geradas pelos

modelos RLM1-RP e RLM2-RP, enquanto que RLM2- σ_p obteve uma dispersão ainda maior com R^2 de 0,1954 para os dados de validação do modelo.

Figura 20 - Representação gráfica dos valores de RP e σ_p observados na literatura em relação aos estimados por regressão linear múltipla no modelo RLM2



Fonte: Autor

4.1.4 Estimativa dos indicadores de capacidade de suporte de carga – RLM3

Na Tabela 13 são exibidas as FPTs geradas para a estimativa dos parâmetros resistência à penetração (RP) e pressão de preconsolidação do solo (σ_p) com seus respectivos coeficientes de determinação (R^2) parciais, totais do modelo RLM3 e da simulação.

Para a FTP de estimativa da resistência à penetração (RP), ao qual o banco de dados é mais numeroso do que os anteriores, observa-se (Tabela 13) a significância, ou seja, o acréscimo das variáveis independentes areia e umidade volumétrica (θ), que obtiveram R^2 parcial de 0,075 e 0,015, respectivamente, visto que para o modelo destaca-se a densidade do solo com R^2 parcial igual a 0,147. Este valor está de acordo com a Tabela 10 que aponta a maior correlação entre a densidade do solo e a resistência à penetração. Ribon e Tavares Filho (2008), também utilizaram a umidade para estimar a RP, porém em sua versão gravimétrica.

A pressão de preconsolidação obteve uma FTP com cinco variáveis independentes significativas em RLM3, sendo que neste modelo a variável que obteve maior destaque foi a MO com coeficiente de determinação parcial (R^2) de 0,162. Junto às demais variáveis independentes significativas (areia, argila,

densidade do solo e umidade volumétrica) o modelo obteve R^2 igual a 0,66.

Tabela 13 - Coeficientes das equações de regressão linear múltipla e de determinação para estimativa da resistência à penetração e da pressão de preconsolidação para a RLM 3

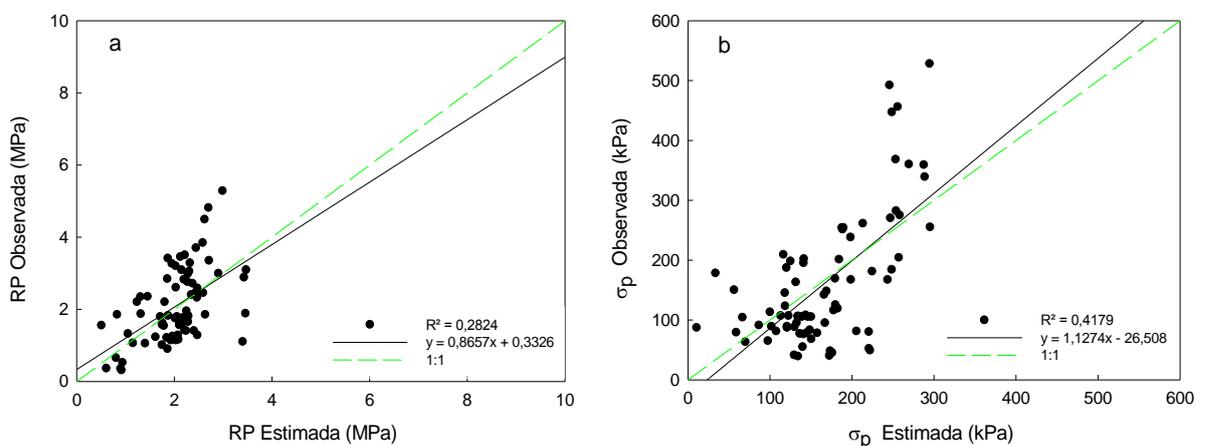
Variáveis	RP		σ_p	
	Coefficiente	R ² Parcial	Coefficiente	R ² Parcial
Constante	-6,362		92,346	
Areia	0,025	0,075	-1,505	0,037
Silte	ns		ns	
Argila	0,053	0,106	2,707	0,146
D _s	4,196	0,147	139,386	0,042
D _p	ns		ns	
P _t	ns		ns	
Mo	ns		-3,331	0,162
θ	-2,75	0,015	-434,243	0,048
R ² - Modelo		0,342		0,660
R ² - Validação		0,2824		0,4179

Fonte: Autor

Areia (%); Silte (%); Argila (%); D_s - densidade do solo (g.cm⁻³); D_p - densidade de partícula (g.cm⁻³); P_t - Porosidade total (cm³. cm⁻³); MO - teor de Matéria orgânica (%); θ - Umidade volumétrica do solo (cm³. cm⁻³); ns – não significativo a 5% de probabilidade de erro.

Apesar de o modelo apresentar o R^2 0,66, o que seria um resultado razoável, os resultados estimados obtidos através do arquivo de dados destinado a validação do modelo obteve um coeficiente de determinação de 0,4179, de tal forma que os valores não se apresentaram tão agrupados a reta (Figura 21-b).

Figura 21 - Representação gráfica dos valores de RP e σ_p observados na literatura em relação aos estimados por regressão linear múltipla no modelo RLM3



Fonte: Autor

4.1.5 Estimativa dos indicadores de capacidade de suporte de carga – RLM4

Na Tabela 14 são apresentadas as FPTs para os parâmetros de capacidade de carga do solo RP e σ_p , referentes aos dados obtidos para formar a RLM4.

A FPT gerada para a predição da resistência do solo à penetração, por meio de regressão linear múltipla, considerou apenas três variáveis significativas (Argila, porosidade total e umidade volumétrica), dentre as sete variáveis independentes presentes em sua arquitetura. Diferente dos três conjuntos de dados anteriores a densidade do solo no RLM4-RP não foi significativa para o modelo, de tal forma que a Argila foi a variável que obteve o maior R^2 parcial (0,207). Esse valor vai de encontro aos maiores coeficientes de correlação (negativo e positivo) com a resistência à penetração do solo para este grupo de dados, que foram a porosidade total e a densidade do solo, respectivamente.

Para a pressão de preconsolidação do solo, diferente de RLM3, os valores parciais de R^2 foram muito baixos de forma a gerar uma FTP com coeficiente de determinação de 17,9%.

Tabela 14 - Coeficientes das equações de regressão linear múltipla e de determinação para estimativa da resistência à penetração e da pressão de preconsolidação para a RLM4

Variáveis	RP		σ_p	
	Coeficiente	R^2 Parcial	Coeficiente	R^2 Parcial
Constante	7,012		295,08	
Areia	ns		-1,404	0,051
Silte	ns		ns	
Argila	0,048	0,207	0,964	0,045
D_s	ns		ns	
D_p	ns		ns	
P_t	-13,768	0,085	ns	
θ	-1,074	0,003	-387,572	0,083
R^2 - Modelo		0,295		0,179
R^2 - Validação		0,163		0,1193

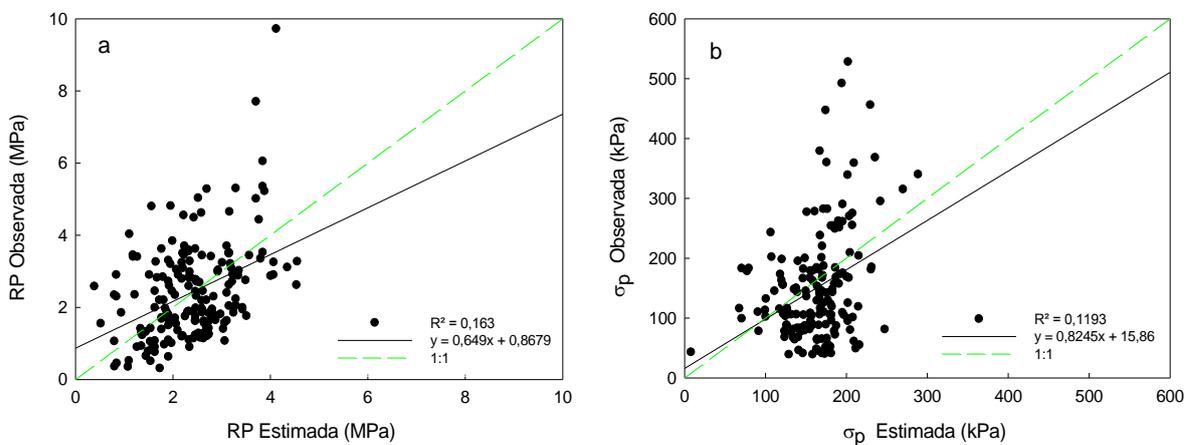
Fonte: Autor

Areia (%); Silte (%); Argila (%); D_s - densidade do solo ($g.cm^{-3}$); D_p - densidade de partícula ($g.cm^{-3}$); P_t - Porosidade total ($cm^3.cm^{-3}$); θ - Umidade volumétrica do solo ($cm^3.cm^{-3}$); ns – não significativo a 5% de probabilidade de erro.

Além do modelo apresentar o R^2 0,179, o que não se caracteriza como um

bom resultado, os resultados estimados obtidos através do arquivo de dados destinado a validação do modelo obteve um coeficiente de determinação ainda pior de 0,1193, (Figura 22-b). O mesmo ocorreu para a estimativa da resistência do solo à penetração, onde o R^2 do modelo foi de 0,295 enquanto o da validação foi 0,163, ou seja, um déficit de 13,2% no poder de cálculo do modelo, o que pode ser visto na grande dispersão apresentada (Figura 22-a).

Figura 22 - Representação gráfica dos valores de RP e σ_p observados na literatura em relação aos estimados por regressão linear múltipla no modelo RLM4



Fonte: Autor

4.1.6 Estimativa dos indicadores de capacidade de suporte de carga – RLM5

As FPTs geradas a partir do modelo RLM5 para a estimativa dos parâmetros resistência à penetração (RP) e pressão de preconsolidação do solo (σ_p) com seus respectivos coeficientes de determinação (R^2) são apresentadas na Tabela 15.

Pode-se notar que modelo RLM5 quando utilizado para estimar a σ_p não apresentou diferenças em relação a RLM4, visto que a variável porosidade total (P_t) não foi significativa ao modelo. Sendo a ausência desta a diferença entre RLM4 e RLM5, os coeficientes em ambos os modelos são iguais.

Para a estimativa da resistência à penetração (RP) a ausência da variável P_t , em RLM5 promoveu variáveis que no modelo RLM4 apresentavam-se como não significativas ao status significativa (D_s e D_p), sendo a densidade de partícula a detentora do maior R^2 parcial (0,187). Ainda assim, o desempenho do modelo foi inferior obtendo R^2 igual a 0,285.

Tabela 15 - Coeficientes das equações de regressão linear múltipla e de determinação para estimativa da resistência à penetração e da pressão de preconsolidação para a RLM5

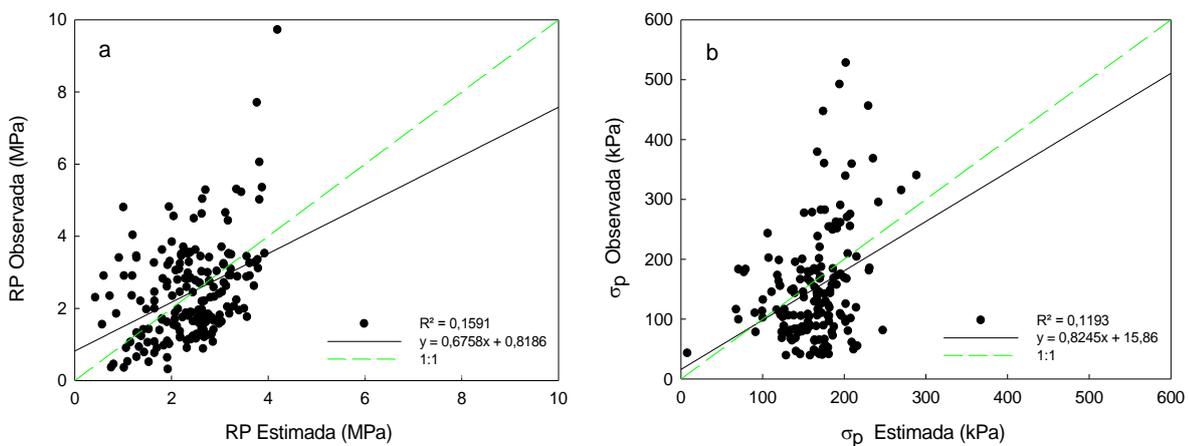
Variáveis	RP		σ_p	
	Coeficiente	R ² Parcial	Coeficiente	R ² Parcial
Constante	1,07		295,08	
Areia	ns		-1,404	0,051
Silte	ns		ns	
Argila	0,052	0,056	0,964	0,045
D _s	5,386	0,036	ns	
D _p	-3,036	0,187	ns	
θ	-1,621	0,006	-387,572	0,083
R ² - Modelo		0,285		0,179
R ² - Validação		0,1591		0,1193

Fonte: Autor

Areia (%); Silte (%); Argila (%); D_s - densidade do solo (g.cm⁻³); D_p - densidade de partícula (g.cm⁻³); θ - Umidade volumétrica do solo (cm³. cm⁻³); ns – não significativo a 5% de probabilidade de erro.

Analisando-se a Figura 23(b) se pode notar a igualdade das FTPs geradas pelos modelos RLM4- σ_p e RLM5- σ_p (R² = 0,1193), enquanto que RLM5-RP (Figura 23-a) obteve uma dispersão ainda maior com R² de 0,1591 para os dados de validação do modelo.

Figura 23 - Representação gráfica dos valores de RP e σ_p observados na literatura em relação aos estimados por regressão linear múltipla no modelo RLM5



Fonte: Autor

4.1.7 Estimativa dos indicadores de capacidade de suporte de carga – RLM6

Observa-se na composição do modelo RLM6 (Tabela 16) apenas as variáveis texturais, densidade do solo (D_s) e conteúdo volumétrico da água (θ), de tal forma que a FPT gerada para estimar a RP obteve um coeficiente de determinação ainda menor que o obtido pelos modelos anteriores (0,130) de maneira que é notório que o comportamento das variáveis independentes em relação a dependente não é linear para o banco de dados composto por solos com várias classes texturais.

Tabela 16 - Coeficientes das equações de regressão linear múltipla e de determinação para estimativa da resistência à penetração e da pressão de preconsolidação para a RLM6

Variáveis	RP		σ_p	
	Coeficiente	R ² Parcial	Coeficiente	R ² Parcial
Constante	-2,221		281,53	
Areia	ns		-1,341	0,048
Silte	ns		ns	
Argila	0,034	0,064	1,094	0,057
D_s	3,093	0,026	ns	
θ	-3,991	0,040	-366,897	0,068
R ² - Modelo		0,130		0,173
R ² - Validação		0,0391		0,1198

Fonte: Autor

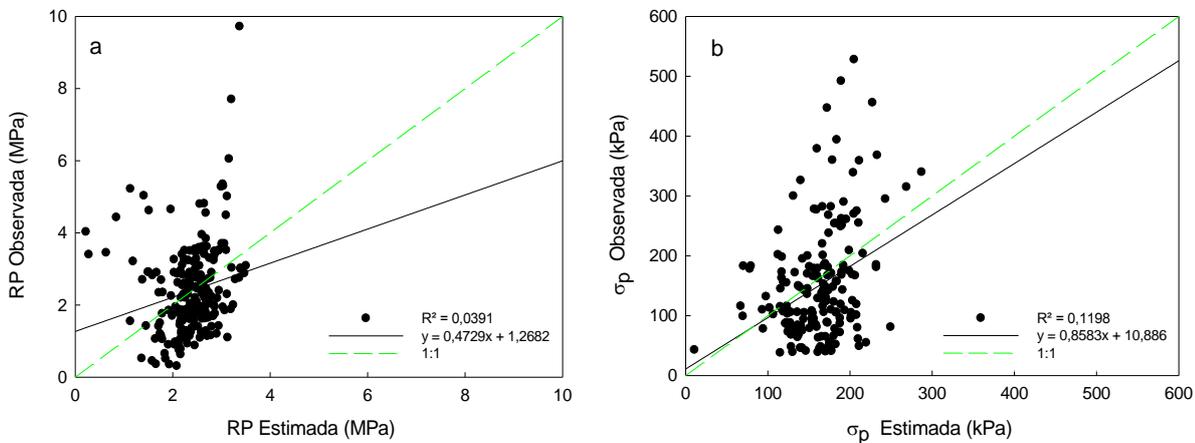
Areia (%); Silte (%); Argila (%); D_s - densidade do solo ($g.cm^{-3}$); θ - Umidade volumétrica do solo ($cm^3.cm^{-3}$); ns – não significativo a 5% de probabilidade de erro.

Entretanto as variáveis consideradas significativas ao modelo RLM6-RP (Argila, D_s e θ) são as mesmas que obtiveram ótimos coeficientes de determinação em estudo realizado por Ribon e Tavares Filho (2008), visto que no estudo desses autores os dados foram levantados de uma única classe textural de solo e o teor de água no solo utilizado pra geração da FTP foi gravimétrico.

A Figura 24(a) mostra a grande diferença entre o R² do modelo (0,130) e o R² da validação (0,0391) perdendo aproximadamente 9% da representatividade.

Como não houve diferença entre as variáveis significativas dos modelos RLM5- σ_p e RLM6- σ_p , estes apresentaram o mesmo coeficiente de determinação (0,1193) como se pode notar na Figura 24(b).

Figura 24 - Representação gráfica dos valores de RP e σ_p observados na literatura em relação aos estimados por regressão linear múltipla no modelo RLM6



Fonte: Autor

4.1.8 Estimativa dos indicadores de capacidade de suporte de carga – RLM7

O modelo RLM7 diferencia-se do anterior pela variável Silte + Argila que é a soma das duas variáveis apresentadas separadamente no modelo RLM6. Na Tabela 17 estão representados os coeficientes das equações de regressão para a estimativa dos parâmetros de capacidade de suporte de carga do solo, a partir do banco de dados obtidos para formar a RLM7.

Tabela 17 - Coeficientes das equações de regressão linear múltipla e de determinação para estimativa da resistência à penetração e da pressão de preconsolidação para a RLM7

Variáveis	RP		σ_p	
	Coeficiente	R ² Parcial	Coeficiente	R ² Parcial
Constante	-1,541		338,512	
Areia	ns		-1,883	0,026
Silte + Argila	0,025	0,035	ns	
D _s	2,506	0,026	ns	
θ	-3,896	0,033	-357,91	0,109
R ² - Modelo		0,094		0,135
R ² - Validação		0,0163		0,117

Fonte: Autor

Areia (%); Silte (%); Argila (%); D_s - densidade do solo (g.cm⁻³); θ - Umidade volumétrica do solo (cm³. cm⁻³); ns – não significativo a 5% de probabilidade de erro.

A FPT formada para a estimativa de resistência à penetração inclui significativamente as variáveis independentes Silte + Argila, D_s e θ . A variável Silte + Argila teve maior influência na equação de predição, pois teve maior valor de R^2 parcial (0,035). Esse valor vai de encontro a maior correlação obtida para o modelo RLM7-RP que se deu com a densidade do solo (Tabela 10).

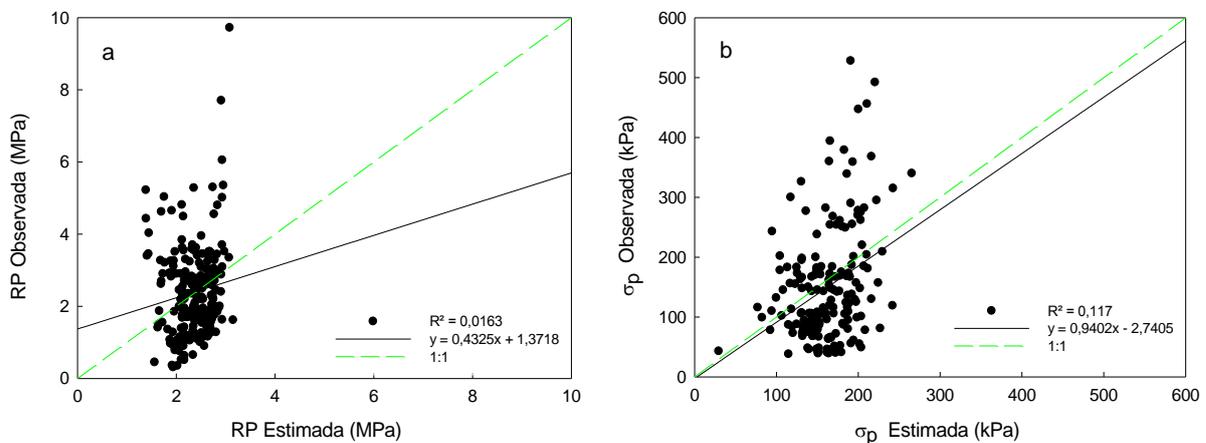
Para a pressão de preconsolidação do solo houve apenas duas variáveis significativas para construção do modelo (Areia e θ) sendo a mais relevante a umidade volumétrica, pois obteve o maior R^2 parcial (0,109)

Os modelos gerados para estimar resistência à penetração (RP) e pressão de preconsolidação do solo (σ_p) foram avaliados quanto a sua capacidade preditiva, através da relação 1:1, entre os dados observados destinados a validação dos modelos e os estimados pelas FPTs (Figura 25).

Pode-se observar que o desempenho do modelo RLM7 com os dados destinados a validação foi inferior ao obtido com os dados de treinamento para ambos os parâmetros (RP e σ_p) sendo que para resistência a penetração (Figura 25-a) a diferença foi muito acentuada, inferindo-se um ajustamento do modelo linear de apenas 1,63%.

O modelo RLM7- σ_p (Figura 25-b) obteve um coeficiente de determinação R^2 de 11,7%, o que também se caracteriza como um resultado ruim, ou seja, o modelo não apresenta-se eficiente para a estimativa da pressão de preconsolidação (σ_p).

Figura 25 - Representação gráfica dos valores de RP e σ_p observados na literatura em relação aos estimados por regressão linear múltipla no modelo RLM7



Fonte: Autor

4.1.9 Estimativa dos indicadores de capacidade de suporte de carga – RLM8

A Tabela 18 apresenta os coeficientes que compõem as FTPs, sendo que a maior contribuição, observada pelo coeficiente de determinação, para as funções geradas foi a Argila, com um R^2 parcial de 0,065 e 0,053 para RP e σ_p respectivamente. Observa-se que a Argila foi a única variável significativa a 5% de probabilidade de erro para compor o modelo de estimativa de pressão de preconsolidação (RLM8- σ_p).

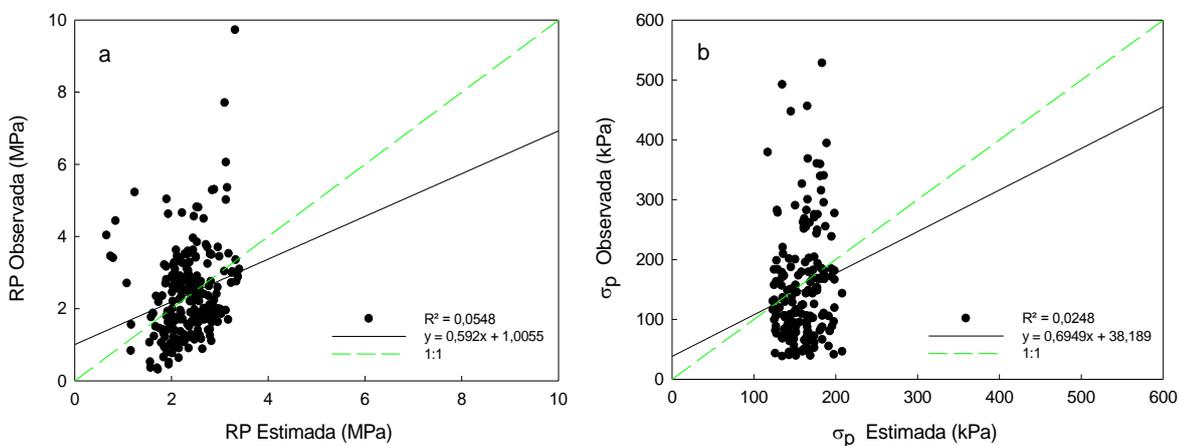
Tabela 18 - Coeficientes das equações de regressão linear múltipla e de determinação para estimativa da resistência à penetração e da pressão de preconsolidação para a RLM8

Variáveis	RP		σ_p	
	Coeficiente	R ² Parcial	Coeficiente	R ² Parcial
Constante	-4,166		116,943	
Areia	0,022	0,015	ns	
Silte	ns		ns	
Argila	0,046	0,065	1,1	0,053
D _s	2,711	0,026	ns	
R ² - Modelo		0,106		0,053
R ² - Validação		0,0548		0,0248

Fonte: Autor

Areia (%); Silte (%); Argila (%); D_s - densidade do solo (g.cm⁻³); ns – não significativo a 5% de probabilidade de erro.

Figura 26 - Representação gráfica dos valores de RP e σ_p observados na literatura em relação aos estimados por regressão linear múltipla no modelo RLM8



Fonte: Autor

Nota-se que a medida de ajustamento do modelo linear tem seu valor reduzido a aproximadamente 50% para as duas FTPs (RLM8-RP e RLM8- σ_p) quando são utilizados os dados destinados à validação dos modelos.

Pode-se notar a grande dispersão dos pontos tanto para relação gráfica que representa a estimativa de resistência do solo à penetração (Figura 26-a) quanto para a representação da estimativa da pressão de preconsolidação (Figura 26-b).

4.1.10 Estimativa dos indicadores de capacidade de suporte de carga – RLM9

O modelo RLM9 é composto pelas frações granulométricas e difere do modelo anterior pela substituição da variável de entrada densidade do solo (D_s) pela umidade volumétrica (θ). Sendo assim, as variáveis significativas para a obtenção das FTPs representadas na Tabela 19 são a argila e a umidade volumétrica (θ) para RLM9-RP e as variáveis areia, argila e umidade volumétrica para RLM9- σ_p .

Para ambas as FTPs a umidade volumétrica (θ) foi a variável de entrada mais influente na obtenção dos valores estimados com valores de R^2 parciais de 0,017 para RLM9-RP e 0,068 para RLM9- σ_p .

Tabela 19 - Coeficientes das equações de regressão linear múltipla e de determinação para estimativa da resistência à penetração e da pressão de preconsolidação para a RLM9

Variáveis	RP		σ_p	
	Coeficiente	R^2 Parcial	Coeficiente	R^2 Parcial
Constante	2,566		281,53	
Areia	ns		-1,341	0,048
Silte	ns		ns	
Argila	0,012	0,008	1,094	0,057
θ	-2,576	0,017	-366,897	0,068
R^2 - Modelo		0,025		0,173
R^2 - Validação		0,0029		0,1198

Fonte: Autor

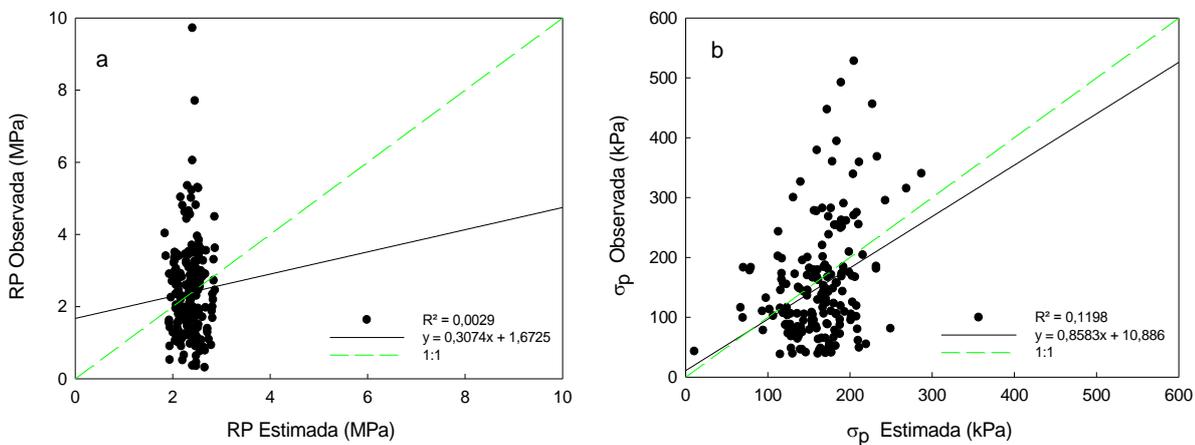
Areia (%); Silte (%); Argila (%); θ - Umidade volumétrica do solo ($\text{cm}^3 \cdot \text{cm}^{-3}$); ns – não significativo a 5% de probabilidade de erro.

Na Figura 27(a) está representado o gráfico considerando os valores observados na literatura e estimados pela FPT, de resistência à penetração (RP). O modelo

apresenta o valor extremamente baixo de R^2 (0,0029), sendo assim sua capacidade preditiva para o parâmetro RP é quase nula.

Como as variáveis independentes significativas ao modelo de estimativa de pressão de preconsolidação são as mesmas para os modelos RLM6- σ_p e RLM9- σ_p , pode-se notar a igualdade das FTPs geradas pelos ao analisar-se a Figura 27(b) onde que apresenta a mesma equação linear e mesmo coeficiente de determinação R^2 (0,1193).

Figura 27 - Representação gráfica dos valores de RP e σ_p observados na literatura em relação aos estimados por regressão linear múltipla no modelo RLM9



Fonte: Autor

4.1.11 Estimativa dos indicadores de capacidade de suporte de carga – RLM10

O modelo RLM10 é composto pelas frações granulométricas e densidade do solo, diferindo do modelo RLM8 pelo fato das frações silte e argila somadas representarem uma única variável de entrada. Desta forma, as variáveis significativas para a obtenção das FTPs representadas na Tabela 20 são a soma argila+silte e a densidade do solo (D_s) para RLM10-RP e a variável areia para RLM10- σ_p .

Pode-se observar que o desempenho do modelo RLM10 com os dados destinados a validação foi inferior ($R^2=0,0195$) ao obtido com os dados de treinamento ($R^2=0,062$) para o parâmetro resistência à penetração (RP). Entretanto o modelo RLM10 se mostrou melhor com os dados destinados a validação, de forma a obter o coeficiente de determinação superior ($R^2=0,0309$) ao obtido com os dados

de treinamento ($R^2=0,026$) para o parâmetro pressão de preconsolidação (σ_p).

Tabela 20 - Coeficientes das equações de regressão linear múltipla e de determinação para estimativa da resistência à penetração e da pressão de preconsolidação para a RLM10

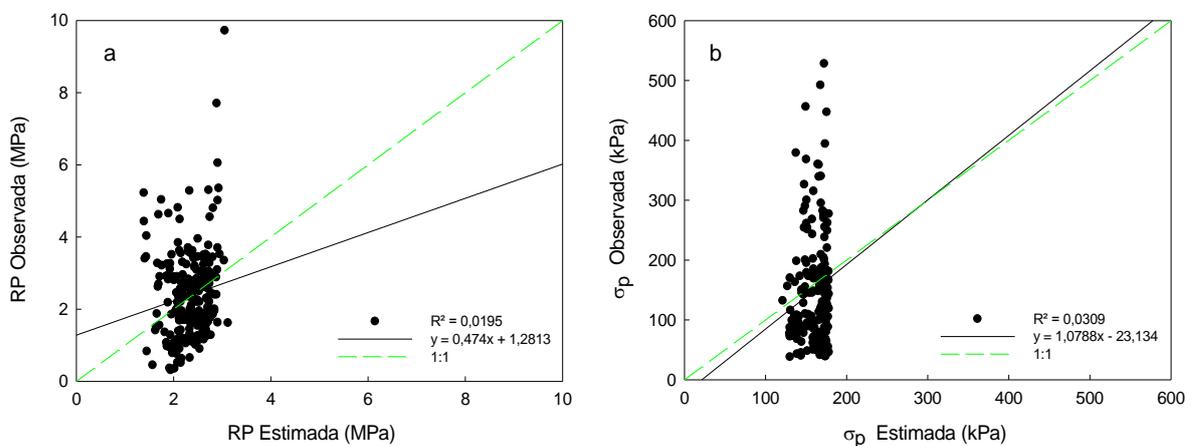
Variáveis	RP		σ_p	
	Coeficiente	R ² Parcial	Coeficiente	R ² Parcial
Constante	-1,327		178,936	
Areia	ns		-0,649	0,026
Silte + Argila	0,013	0,036	ns	
D _s	2,071	0,026	ns	
R ² - Modelo		0,062		0,026
R ² - Validação		0,0195		0,0309

Fonte: Autor

Areia (%); Silte (%); Argila (%); D_s - densidade do solo (g.cm⁻³); ns – não significativo a 5% de probabilidade de erro.

Ainda assim, o modelo RLM10 obteve um grau de dispersão muito elevado tanto para estimativa da RP quanto para σ_p (Figura 28), não sendo adequado à obtenção de tais parâmetros. Isto corrobora com resultados obtidos por Braga (2014), que utiliza em um de seus modelos as mesmas variáveis de entrada para estimar a coesão e o ângulo de atrito interno do solo, sendo estes parâmetros também indicadores de capacidade de carga do solo.

Figura 28 - Representação gráfica dos valores de RP e σ_p observados na literatura em relação aos estimados por regressão linear múltipla no modelo RLM10



Fonte: Autor

4.1.12 Estimativa dos indicadores de capacidade de suporte de carga – RLM11

Constituído pelas frações granulométricas e umidade volumétrica, o modelo RLM11 difere do modelo RLM9 pelo fato das frações argila e silte somadas representarem uma única variável de entrada. Desta forma, as variáveis significativas para a obtenção das FTPs representadas na Tabela 21 são a areia e a umidade volumétrica do solo (θ) tanto para RLM11-RP quanto para RLM11- σ_p .

Assim como em RLM9, para ambas as FTPs a umidade volumétrica (θ) foi a variável de entrada mais influente na obtenção dos valores estimados com valores de R^2 parciais de 0,016 para RLM11-RP e 0,109 para RLM11- σ_p .

Observou-se que o desempenho do modelo RLM11 com os dados destinados a validação foi inferior ($R^2=0,0195$) ao obtido com os dados de treinamento ($R^2=0,062$) para o parâmetro resistência à penetração (RP).

Tabela 21 - Coeficientes das equações de regressão linear múltipla e de determinação para estimativa da resistência à penetração e da pressão de preconsolidação para a RLM11

Variáveis	RP		σ_p	
	Coeficiente	R^2 Parcial	Coeficiente	R^2 Parcial
Constante	3,433		338,512	
Areia	-0,01	0,001	-1,883	0,026
Silte + Argila	ns		ns	
θ	-2,517	0,016	-357,91	0,109
R^2 - Modelo		0,017		0,135
R^2 - Validação		0,00005		0,117

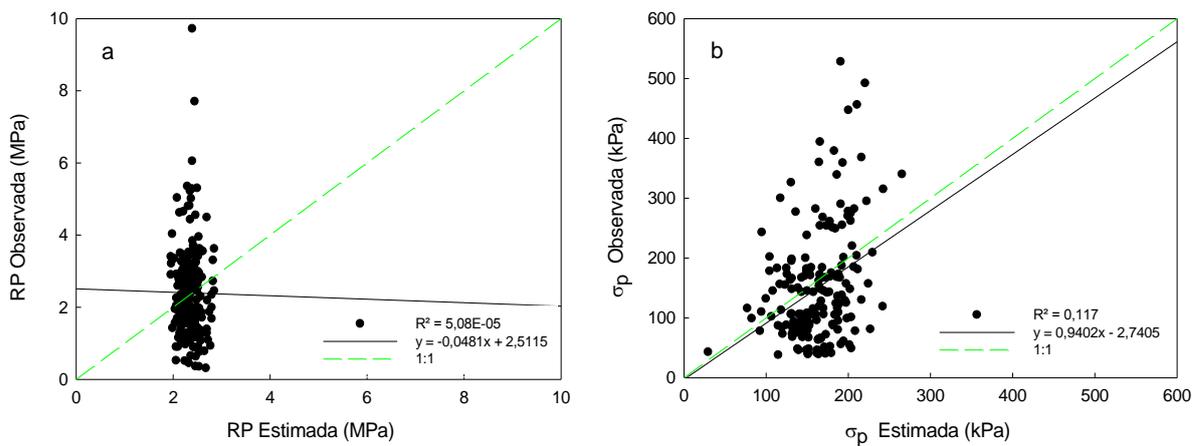
Fonte: Autor

Areia (%); Silte (%); Argila (%); θ - Umidade volumétrica do solo ($\text{cm}^3 \cdot \text{cm}^{-3}$); ns – não significativo a 5% de probabilidade de erro.

Pode-se notar a grande dispersão dos pontos tanto para relação gráfica que representa a estimativa de resistência do solo à penetração (Figura 29-a) quanto para a representação da estimativa da pressão de preconsolidação (Figura 29-b). Percebe-se que a medida de ajustamento do modelo linear tem seu valor reduzido a mais 99% para a FTP gerada pelo modelo RLM11-RP quando são utilizados os dados destinados à validação do modelo, de tal forma que a reta proveniente da FTP apresenta-se decrescente (Figura 29-b) e com valor de R^2 igual a 0,005%,

apresentando-se como o pior dentre os modelos gerados para estimativa de RP. Todavia, para a estimativa da pressão de preconsolidação o modelo RLM11- σ_p se apresentou semelhante ao modelo RLM7- σ_p , visto que as variáveis significativas foram as mesmas.

Figura 29 - Representação gráfica dos valores de RP e σ_p observados na literatura em relação aos estimados por regressão linear múltipla no modelo RLM11



Fonte: Autor

4.1.13 Estimativa dos indicadores de capacidade de suporte de carga – RLM12

Observa-se na composição do modelo RLM12 (Tabela 22) apenas as variáveis texturais, de tal forma que a FPT gerada para estimar a RP obteve um coeficiente de determinação ainda menor que o obtido pelos modelos anteriores (0,013) sendo o silte a única variável independente significativa. Entretanto, utilizando-se o banco de dados destinado à validação o R^2 foi superior ao obtido no treinamento, passando de 0,013 no treinamento a 0,0252 na validação (Figura 30-a).

Para a estimativa da pressão de preconsolidação a areia foi a única variável independente significativa com o coeficiente de determinação parcial de 0,045 (Tabela 22).

Tabela 22 - Coeficientes das equações de regressão linear múltipla e de determinação para estimativa da resistência à penetração e da pressão de preconsolidação para a RLM12

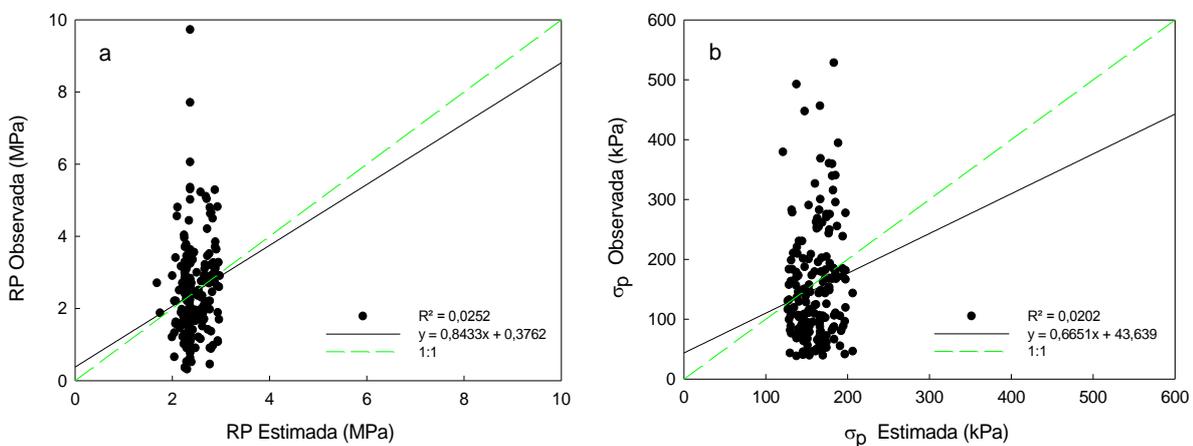
Variáveis	RP		σ_p	
	Coeficiente	R ² Parcial	Coeficiente	R ² Parcial
Constante	2,993		121,029	
Areia	ns		0,992	0,045
Silte	-0,027	0,013	ns	
Argila	ns		ns	
R ² - Modelo		0,013		0,045
R ² - Validação		0,0252		0,0202

Fonte: Autor

Areia (%); Silte (%); Argila (%); ns – não significativo a 5% de probabilidade de erro.

Apesar de o modelo mostrar-se melhor para a obtenção da pressão de preconsolidação, a Figura 30-b mostra grande dispersão para o banco de dados destinado validação. Sendo assim o R² cai de 0,045 no modelo para 0,0202 na validação.

Figura 30 - Representação gráfica dos valores de RP e σ_p observados na literatura em relação aos estimados por regressão linear múltipla no modelo RLM12



Fonte: Autor

4.1.14 Estimativa dos indicadores de capacidade de suporte de carga – RLM13

Semelhante ao modelo não-linear desenvolvido por Busscher (BUSSCHER, 1990) o modelo RLM13 é composto pelas variáveis densidade do solo (D_s) e umidade volumétrica (θ).

A Tabela 23 apresenta apenas a densidade do solo como variável independente significativa ao modelo RLM13-RP com R^2 igual a 0,026. Para o modelo RLM13- σ_p ambas as variáveis de entrada foram significativas, sendo a umidade volumétrica a que possui maior R^2 parcial (0,026).

Tabela 23 - Coeficientes das equações de regressão linear múltipla e de determinação para estimativa da resistência à penetração e da pressão de preconsolidação para a RLM13

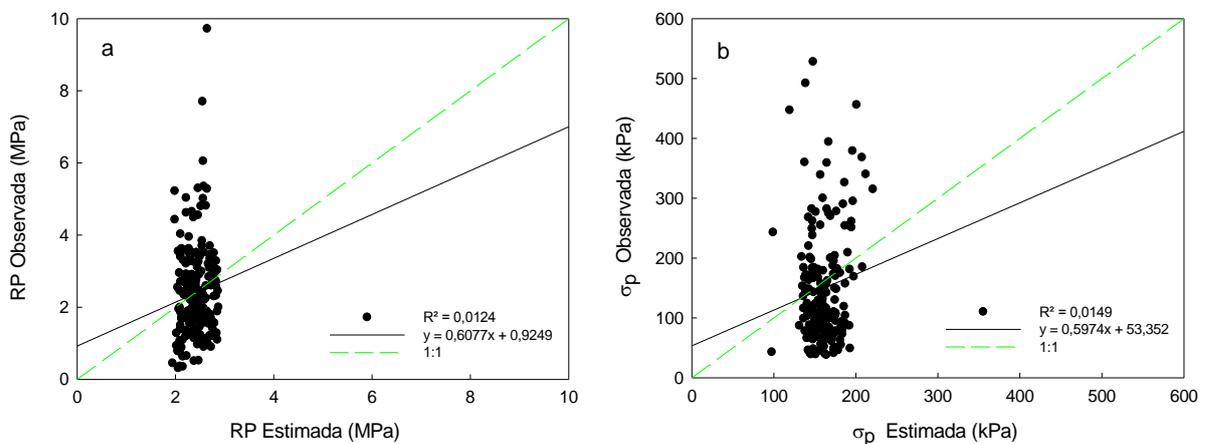
Variáveis	RP		σ_p	
	Coeficiente	R ² Parcial	Coeficiente	R ² Parcial
Constante	0,836		307,42	
D _s	1,153	0,026	-75,068	0,017
θ	ns	0,000	-130,079	0,026
R ² - Modelo		0,026		0,043
R ² - Validação		0,0124		0,0149

Fonte: Autor

D_s - densidade do solo (g.cm⁻³); θ - Umidade volumétrica do solo (cm³. cm⁻³); ns – não significativo a 5% de probabilidade de erro.

Pode-se observar (Figura 31) que o desempenho do modelo RLM13 com os dados destinados a validação foi inferior ao obtido com os dados de treinamento tanto para o parâmetro resistência à penetração ($R^2=0,0124$), quanto para a pressão de preconsolidação ($R^2=0,0149$), o que demonstra a baixa eficiência do modelo.

Figura 31 - Representação gráfica dos valores de RP e σ_p observados na literatura em relação aos estimados por regressão linear múltipla no modelo RLM13



Fonte: Autor

4.2 VALORES ESTIMADOS POR REDES NEURAIS ARTIFICIAIS (RNA)

Esta seção apresenta os resultados estimados das propriedades físico-mecânicas que se caracterizam por estimar a capacidade de suporte de carga do solo agrícola (resistência à penetração e pressão de preconsolidação) obtidos para cada um dos treze conjuntos de dados sem distinção de classe textural, e outros três conjuntos com classe textural distintas, através de Redes Neurais Artificiais (RNA).

Sendo assim, foram testadas dezesseis redes neurais artificiais (RNA1, RNA2, RNA3, RNA4, RNA5, RNA6, RNA7, RNA8, RNA9, RNA10, RNA11, RNA12, RNA13, RNA-FA1, RNA-FA2 e RNA-MA). Cada uma dessas redes neurais é composta de diferentes entradas (Tabela 4), tendo como saídas a resistência à penetração (RP) e a pressão de preconsolidação (σ_p), estimadas separadamente. A arquitetura entre elas foi a mesma (feed-forward back-propagation com 1 camada oculta na rede), sendo modificada somente a topologia dessas redes. Cada topologia utilizada variou além das variáveis independentes de entrada e as variáveis dependentes de saída, o número de neurônios da camada escondida (10, 20, 30, 40 e 50 neurônios).

A seguir são apresentados graficamente os resultados da melhor topologia para cada uma das RNA estudadas, sendo apresentados também os respectivos coeficientes de determinação.

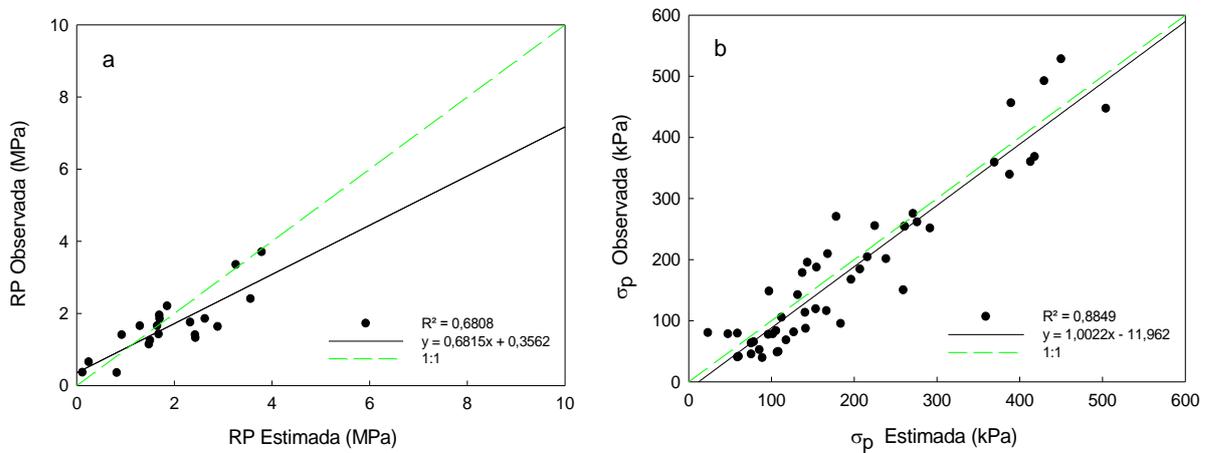
4.2.1 Estimativa dos indicadores de capacidade de suporte de carga – RNA1

A topologia da RNA1 que melhor estimou a resistência do solo à penetração (RP), foi a constituída por 30 neurônios na camada intermediária e foi treinada 15 vezes. Para a estimativa da pressão de preconsolidação do solo (σ_p) a topologia da RNA1 que obteve o melhor resultado também possuía 30 neurônios, porém necessitou de apenas 9 repetições no treinamento.

A seguir, na Figura 32, são apresentados os gráficos que ilustram a correlação entre os valores observados e os estimados de resistência do solo à penetração (Figura 32-a) e de pressão de preconsolidação do solo (Figura 32-b). Observa-se que o ajustamento dos valores obtidos na literatura com os estimados pela RNA1, para RP apresentam certa dispersão, entretanto, a reta representa os

dados a um nível aceitável, visto que o coeficiente de determinação R^2 foi de 0,6808. O ajustamento obtido pela RNA1 foi ainda superior para a σ_p , visto que se distribuiu de forma linear e forma um ângulo de 45° posicionado logo abaixo, porém muito próximo da reta que passa na origem dos eixos, o que correspondeu ao coeficiente de determinação igual a 0,8849.

Figura 32 - Representação gráfica dos valores de RP e σ_p observados na literatura em relação aos estimados por redes neurais artificiais no modelo RNA1



Fonte: Autor

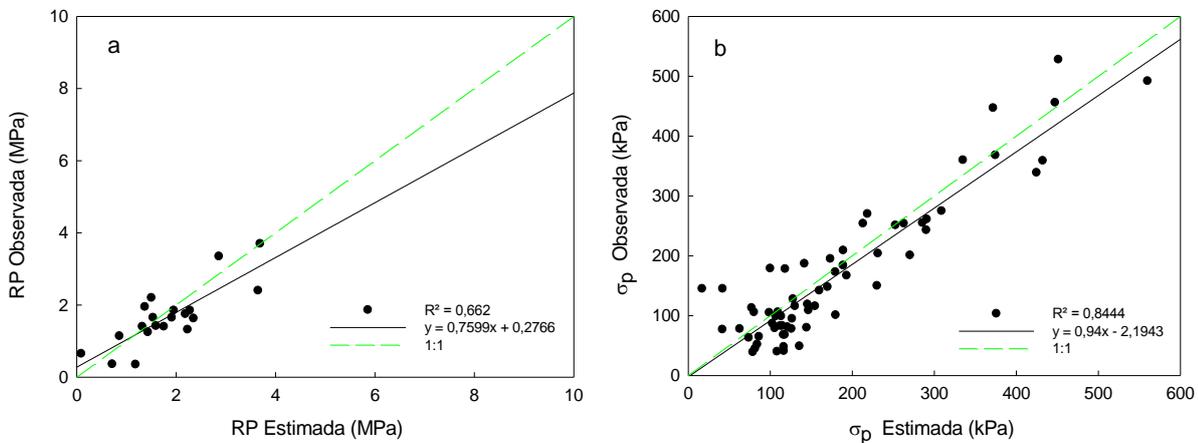
4.2.2 Estimativa dos indicadores de capacidade de suporte de carga – RNA2

As Figuras 33-a e 33-b apresentam a relação gráfica entre os valores estimados e observados de resistência do solo à penetração (RP) e de pressão de preconsolidação do solo (σ_p), respectivamente.

Para a arquitetura RNA2 os melhores resultados preditivos foram obtidos utilizando-se, na camada escondida, 10 neurônios para estimativa de RP e 30 neurônios para σ_p , sendo 7 o número de repetições do processo de treinamento da RNA2-RP e 17 o número de repetições do processo de treinamento da RNA2- σ_p .

Apesar de aproximados os valores dos coeficientes de determinação (R^2) foram inferiores aos obtidos em RNA1, visto que RNA2 obteve 0,6620 para resistência do solo à penetração (Figura 33-a) e 0,8444 para pressão de preconsolidação do solo (Figura 33-b), podendo-se observar nesta última uma inclinação na reta gerada que não havia no modelo anterior (RNA1- σ_p).

Figura 33 - Representação gráfica dos valores de RP e σ_p observados na literatura em relação aos estimados por redes neurais artificiais no modelo RNA2



Fonte: Autor

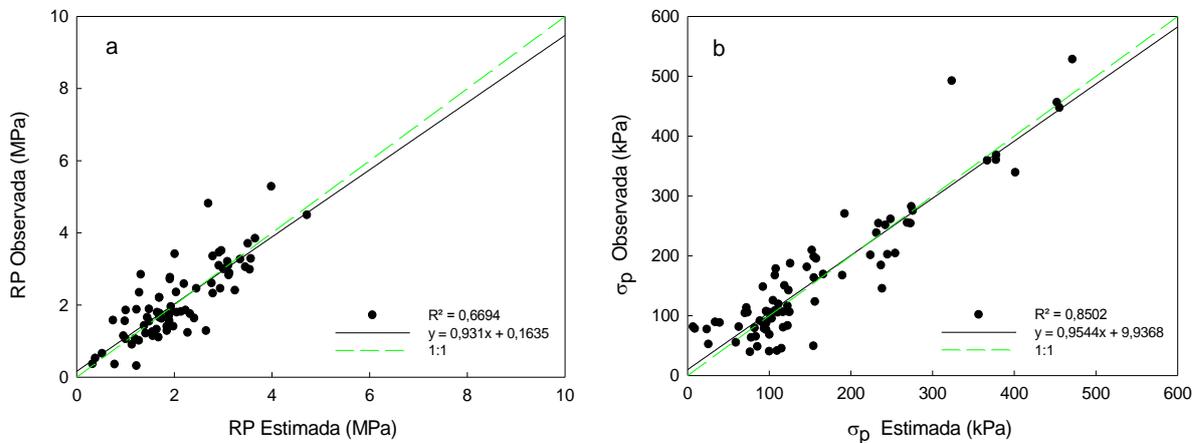
4.2.3 Estimativa dos indicadores de capacidade de suporte de carga – RNA3

Na RNA3, dentre as topologias utilizadas no estudo, as que demonstraram maior capacidade preditiva foram a composta por 10 neurônios na camada escondida e 7 treinamentos para RP, e a composta por 30 neurônios e 25 treinamentos para σ_p .

Pode-se notar (Figura 34-a) que o modelo RNA3-RP, diferente dos vistos anteriormente, apresenta uma reta com inclinação bem mais próxima a da reta 1:1, apesar de seu coeficiente de determinação (0,6694) ser um pouco inferior ao obtido no modelo RNA1.

É possível observar na Figura 34-b, que o coeficiente de determinação R^2 para RNA3- σ_p (0,8502) também foi inferior ao obtido em RNA1- σ_p e superior ao obtido em RNA2- σ_p , assim como o que ocorreu com a RNA3-RP, de forma a se deduzir que a variável de entrada matéria orgânica (MO) exerce maior influência que as variáveis de entrada limites de liquidez (LL) e limite de plasticidade (LP) para a estimativa da capacidade de suporte de carga do solo por RNA, corroborando com Ribon e Tavares Filho (2008) que citam a MO como variável de entrada que contribui efetivamente para estimar a resistência do solo à penetração (RP) e com Mazurana (2011) que obteve resultado aceitável utilizando apenas MO para estimar a pressão de preconsolidação do solo (σ_p).

Figura 34 - Representação gráfica dos valores de RP e σ_p observados na literatura em relação aos estimados por redes neurais artificiais no modelo RNA3



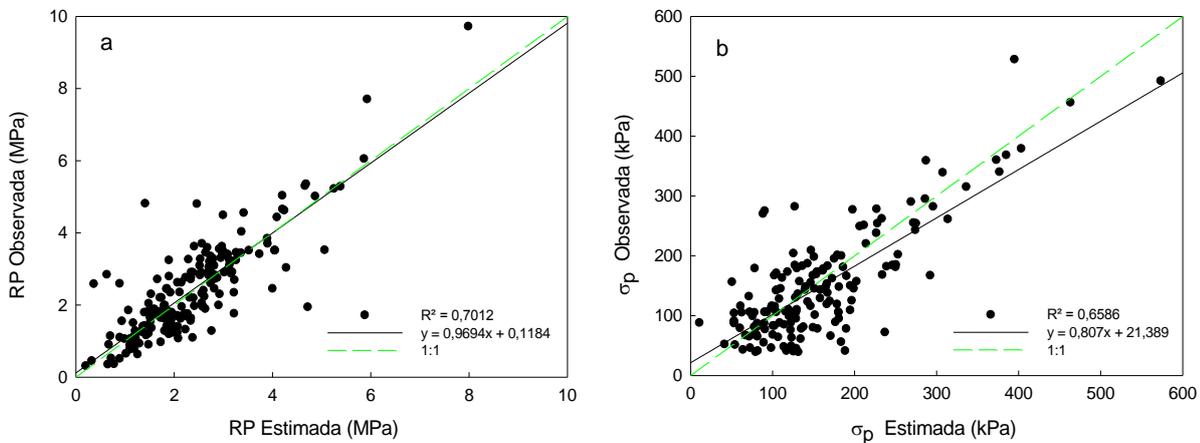
Fonte: Autor

4.2.4 Estimativa dos indicadores de capacidade de suporte de carga – RNA4

A topologia do modelo RNA4 que apresentou melhor capacidade preditiva para resistência do solo à penetração (RP) foi composta por 40 neurônios na camada intermediária e foi treinada apenas 3 vezes. Para a estimativa da pressão de preconsolidação do solo (σ_p) a topologia da RNA4 que obteve o melhor resultado foi a com 30 neurônios e 13 repetições no treinamento.

Na Figura 35, são apresentados os gráficos que ilustram a correlação entre os valores observados e estimados de resistência do solo à penetração (Figura 35-a) e de pressão de preconsolidação do solo (Figura 35-b). Observa-se que o ajustamento dos valores obtidos na literatura com os estimados pela RNA4, para RP apresentam pouca dispersão, visto que o coeficiente de determinação R^2 foi de 0,7012, valor superior aos anteriores, além de apresentar uma reta com inclinação bem próxima a da reta 1:1. Entretanto, o ajustamento obtido pela RNA4 foi inferior para a σ_p , visto uma maior dispersão dos dados, o que correspondeu ao coeficiente de determinação (R^2) igual a 0,6586. Isto demonstra a importância das variáveis independentes matéria orgânica (MO), limites de liquidez (LL) e limite de plasticidade (LP) para a estimativa da pressão de preconsolidação do solo (σ_p), o que significou uma perda da capacidade preditiva de aproximadamente 23% do modelo detentor destas variáveis em sua arquitetura (RNA1).

Figura 35 - Representação gráfica dos valores de RP e σ_p observados na literatura em relação aos estimados por redes neurais artificiais no modelo RNA4



Fonte: Autor

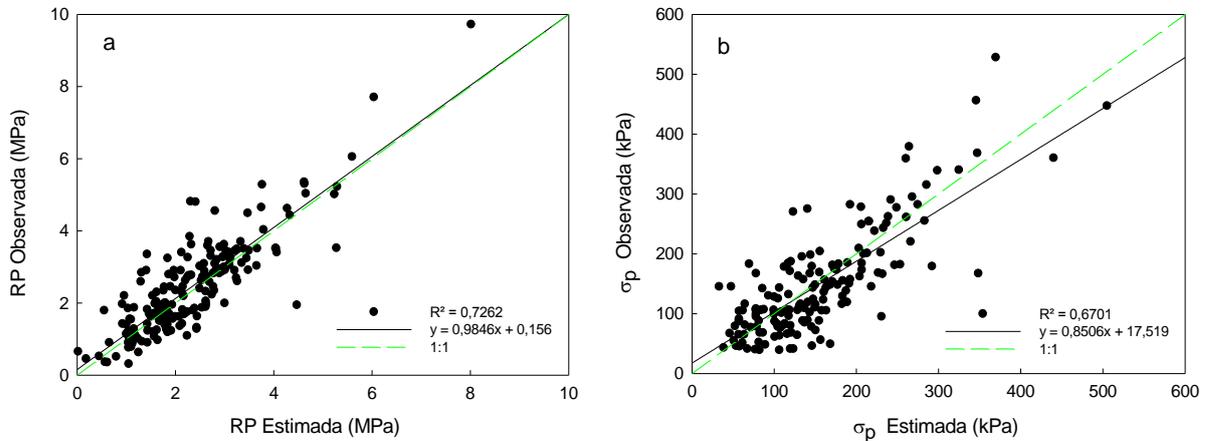
4.2.5 Estimativa dos indicadores de capacidade de suporte de carga – RNA5

No modelo RNA5, a estimativa da resistência do solo à penetração (RP) obteve o melhor resultado ao se utilizar a topologia constituída por 50 neurônios na camada intermediária e 5 repetições no treinamento da rede. A topologia da RNA5 que obteve o melhor resultado para a estimativa da pressão de preconsolidação do solo (σ_p), da mesma forma que nos modelos anteriores, foi a composta por 30 neurônios, e necessitou de 25 repetições no treinamento.

As Figuras 36-a e 36-b apresentam a relação gráfica entre os valores estimados e observados de resistência do solo à penetração (RP) e de pressão de preconsolidação do solo (σ_p), respectivamente.

Nota-se que o ajustamento dos valores obtidos na literatura com os estimados pela RNA5-RP (Figura 36-a) foram ainda melhores que o modelo anterior (RNA4-RP), visto que o coeficiente de determinação (R^2) foi de 0,7262, além de apresentar uma reta com inclinação muito próxima a da reta 1:1. O ajustamento obtido pela RNA5- σ_p (Figura 36-b) foi superior somente ao modelo RNA4- σ_p , apresentando coeficiente de determinação (R^2) igual a 0,6701, podendo ser considerado uma boa opção de estimativa, visto que utiliza um número reduzido de variáveis de entrada.

Figura 36 - Representação gráfica dos valores de RP e σ_p observados na literatura em relação aos estimados por redes neurais artificiais no modelo RNA5



Fonte: Autor

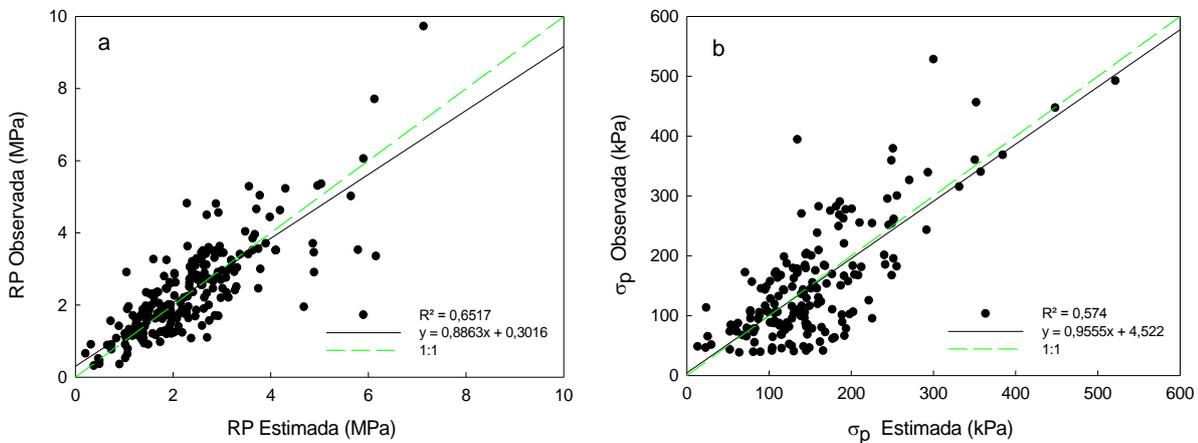
4.2.6 Estimativa dos indicadores de capacidade de suporte de carga – RNA6

Na RNA6 as topologias que demonstraram maior capacidade preditiva foram a composta por 50 neurônios na camada escondida e 10 treinamentos para RP, e a composta por 30 neurônios e 17 treinamentos para σ_p .

Pode-se notar (Figura 37-a) que o modelo RNA6-RP, diferente do visto anteriormente (RNA5-RP), apresenta uma reta com inclinação mais afastada da reta 1:1, apresentando um coeficiente de determinação de 0,6517, sendo este o valor um pouco inferior ao obtido nos modelos anteriores. Este resultado pode ser explicado em função da ausência da variável independente densidade de partícula (D_p) na arquitetura do modelo, sendo que esta variável é uma boa indicadora dos constituintes mineralógicos dos solos que por sua vez influem na resistência à penetração dos mesmos.

É possível observar na Figura 37-b, que o coeficiente de determinação R^2 para RNA6- σ_p (0,5740) também foi inferior aos obtidos anteriormente, assim como o que ocorreu com a RNA6-RP, de forma a se deduzir que a variável de entrada densidade de partícula (D_p) exerce forte influência para a estimativa da capacidade de suporte de carga do solo. Cabe salientar que os valores de densidade de partícula (D_p) são fortemente influenciados pelo teor de matéria orgânica (REICHARDT, 1975), que como abordado anteriormente é uma variável de entrada que se correlaciona fortemente com as variáveis dependentes em estudo.

Figura 37 - Representação gráfica dos valores de RP e σ_p observados na literatura em relação aos estimados por redes neurais artificiais no modelo RNA6



Fonte: Autor

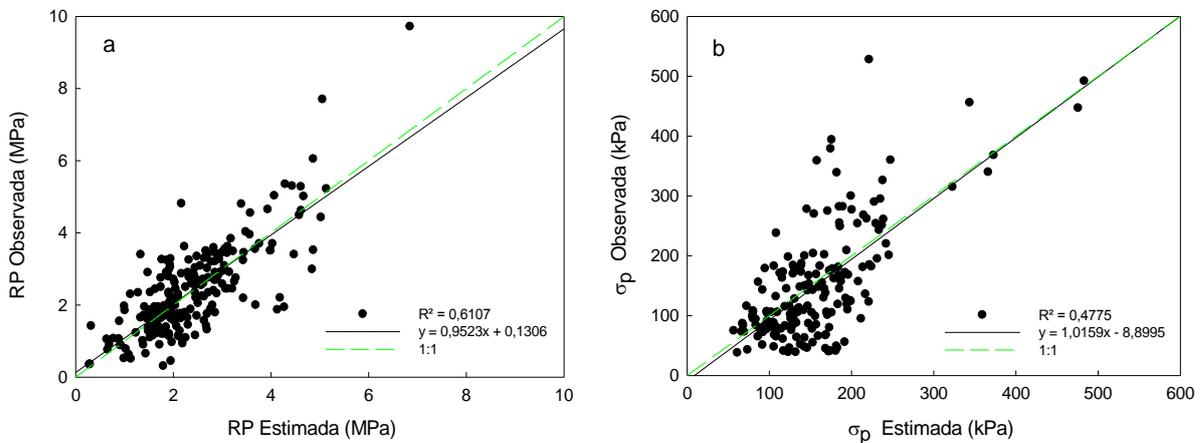
4.2.7 Estimativa dos indicadores de capacidade de suporte de carga – RNA7

As Figuras 38-a e 38-b apresentam a relação gráfica entre os valores estimados e observados de resistência do solo à penetração (RP) e de pressão de preconsolidação do solo (σ_p), respectivamente.

O modelo RNA7 diferencia-se do anterior pela variável Silte + Argila que é a soma das duas variáveis apresentadas separadamente no modelo RNA6. Para a arquitetura RNA7 os melhores resultados preditivos foram obtidos utilizando-se, na camada escondida, 50 neurônios tanto para estimativa de ambos da resistência do solo à penetração (RP) quanto para pressão de preconsolidação (σ_p), sendo 7 o número de repetições do processo de treinamento da RNA7-RP e 8 o número de repetições do processo de treinamento da RNA7- σ_p .

Nota-se que com a soma das variáveis de entrada que correspondem às partículas finas do solo (silte e argila) os valores dos coeficientes de determinação (R^2) foram inferiores aos obtidos em RNA6, visto que RNA7 obteve 0,6107 para resistência do solo à penetração (Figura 38-a) e 0,4775 para pressão de preconsolidação do solo (Figura 38-b), apesar de se observar uma inclinação na reta gerada muito próxima a reta 1:1, o que não ocorreu no modelo anterior (RNA6).

Figura 38 - Representação gráfica dos valores de RP e σ_p observados na literatura em relação aos estimados por redes neurais artificiais no modelo RNA7



Fonte: Autor

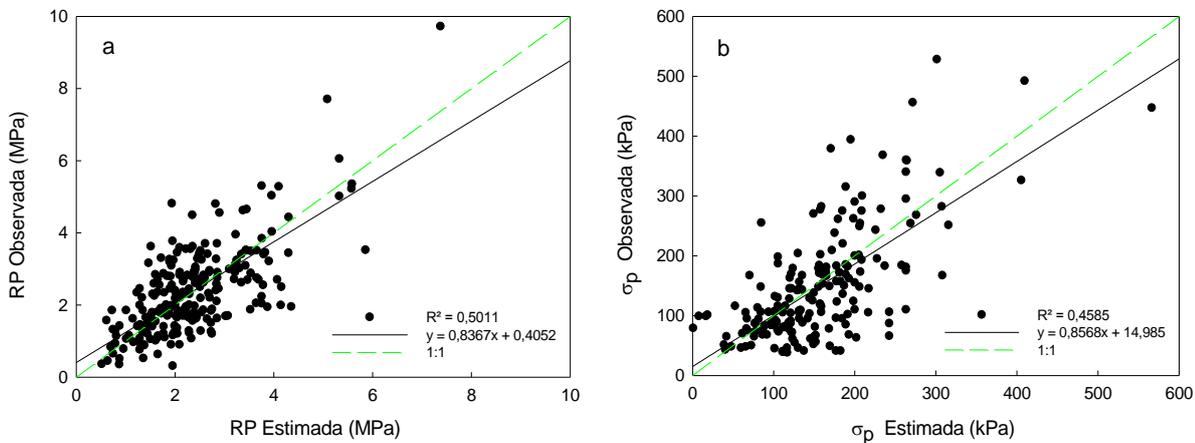
4.2.8 Estimativa dos indicadores de capacidade de suporte de carga – RNA8

A topologia da RNA8 que melhor estimou a resistência do solo à penetração (RP), foi a constituída por 50 neurônios na camada intermediária e foi treinada 3 vezes. Para a estimativa da pressão de preconsolidação do solo (σ_p) a topologia da RNA8 que obteve o melhor resultado possuía 20 neurônios e necessitou de 13 repetições no treinamento.

A seguir, na Figura 39, são apresentados os gráficos que ilustram a correlação entre os valores observados e os estimados de resistência do solo à penetração (Figura 39-a) e de pressão de preconsolidação do solo (Figura 39-b).

Observa-se que o ajustamento dos valores obtidos na literatura com os estimados pela RNA8, para RP apresentam grande dispersão, visto que o coeficiente de determinação (R^2) foi de 0,5011. O ajustamento obtido pela RNA8 foi ainda inferior para a σ_p , o que correspondeu ao coeficiente de determinação igual a 0,4585. Visto que neste modelo (RNA8) a umidade volumétrica do solo (θ) foi a variável de entrada excluída, os baixos valores de R^2 demonstram a importância do conteúdo de água no solo para a capacidade de suporte de carga deste, concordando com estudos de vários autores (AJAYI, 2010; BUSSCHER, 1990; DEBIASE, 2008; DIAS JUNIOR, 2004; GUBIANI, 2012; MOSADDEGHI, 2006; RIBON; TAVARES FILHO, 2008).

Figura 39 - Representação gráfica dos valores de RP e σ_p observados na literatura em relação aos estimados por redes neurais artificiais no modelo RNA8



Fonte: Autor

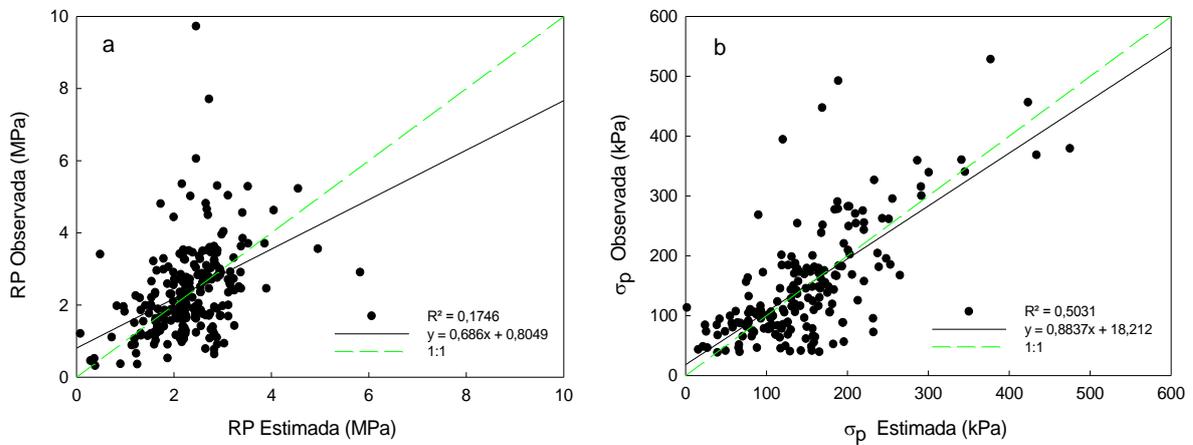
4.2.9 Estimativa dos indicadores de capacidade de suporte de carga – RNA9

O modelo RNA9 é composto pelas frações granulométricas e pela umidade volumétrica (θ). Neste modelo as topologias que demonstraram maior capacidade preditiva foram a composta por 50 neurônios na camada escondida e 4 treinamentos para RP, e a composta por 30 neurônios e também 4 treinamentos para σ_p .

Observa-se (Figura 40-a) que o ajustamento dos valores obtidos na literatura com os estimados pela RNA9, para resistência do solo à penetração (RP), apresentam uma dispersão muito acentuada, visto que o coeficiente de determinação (R^2) foi de 0,1746, enquanto o ajustamento obtido pela RNA9 para a σ_p foi bem superior, o que correspondeu ao coeficiente de determinação igual a 0,5031 (Figura 40-b).

Estes resultados comparados ao modelo anterior (RNA8) apontam que a variável densidade do solo (D_s) apesar de ser de grande importância para a determinação de ambos os indicadores de capacidade de suporte de carga do solo (RP e σ_p), exerce maior influência na obtenção da resistência à penetração, enquanto a pressão de preconsolidação é mais suscetível à variação do conteúdo de água no solo (θ).

Figura 40 - Representação gráfica dos valores de RP e σ_p observados na literatura em relação aos estimados por redes neurais artificiais no modelo RNA9



Fonte: Autor

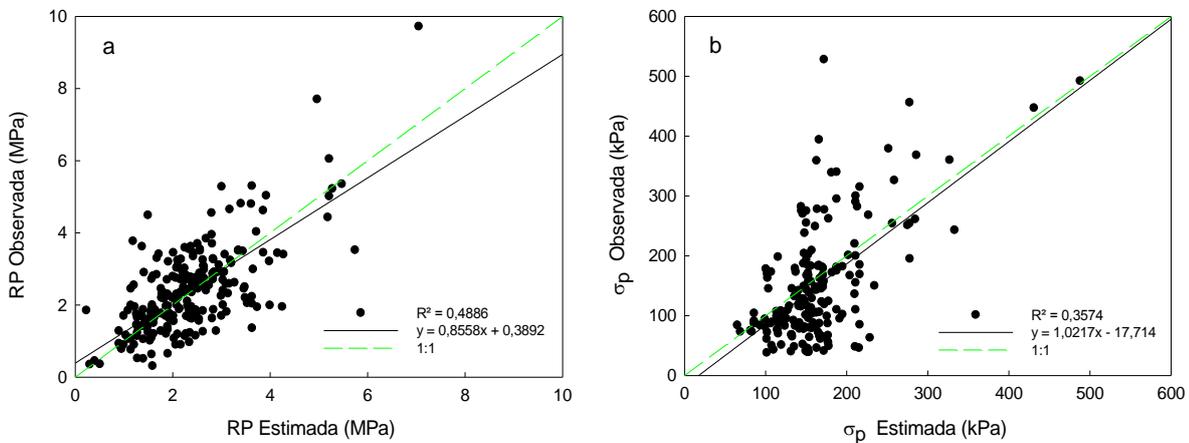
4.2.10 Estimativa dos indicadores de capacidade de suporte de carga – RNA10

A arquitetura do modelo RNA10 tem em sua camada de entrada as frações granulométricas e a densidade do solo, diferindo do modelo RNA8 pelo fato das frações silte e argila somadas representarem uma única variável de entrada.

A topologia da RNA10 que melhor estimou a resistência do solo à penetração (RP), foi a constituída por 20 neurônios na camada intermediária e foi treinada 3 vezes. Para a estimativa da pressão de preconsolidação do solo (σ_p) a topologia da RNA10 que obteve o melhor resultado também possuía 20 neurônios e foi treinada somente 8 vezes.

Observou-se, assim como no modelo RNA7, que com a adição das variáveis independentes de entrada que correspondem às partículas finas do solo (silte e argila) os valores dos coeficientes de determinação (R^2) de RNA10 foram inferiores aos obtidos em RNA8 (Figura 39), obtendo-se 0,4886 para resistência do solo à penetração (Figura 41-a) e 0,3574 para pressão de preconsolidação do solo (Figura 41-b).

Figura 41 - Representação gráfica dos valores de RP e σ_p observados na literatura em relação aos estimados por redes neurais artificiais no modelo RNA10



Fonte: Autor

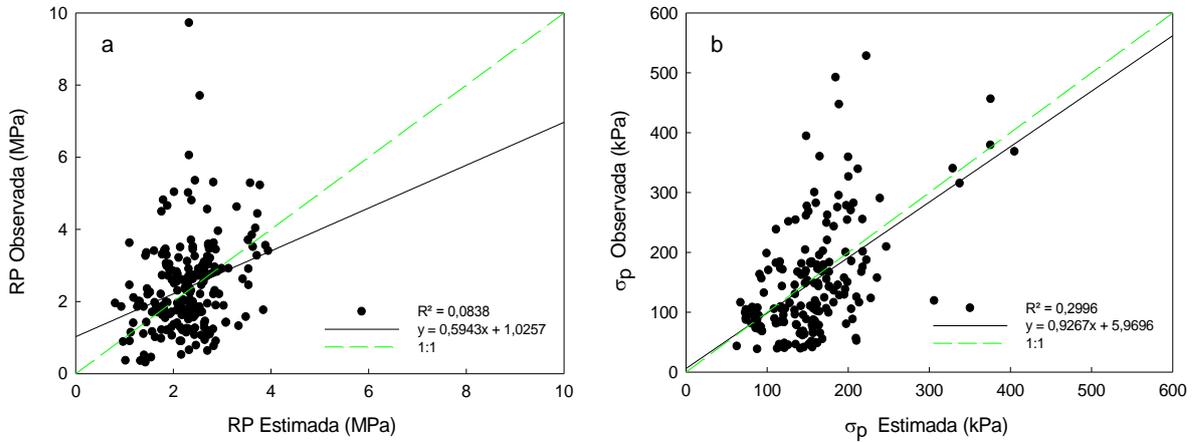
4.2.11 Estimativa dos indicadores de capacidade de suporte de carga – RNA11

O modelo RNA11 tem em sua arquitetura a camada de entrada composta pelas frações granulométricas e a umidade volumétrica, diferindo do modelo RNA9 pelo fato das frações silte e argila somadas representarem uma única variável de entrada.

A topologia da RNA11 que apresentou melhor capacidade preditiva para resistência do solo à penetração (RP), foi a composta por 50 neurônios na camada intermediária e foi treinada 13 vezes. Para a estimativa da pressão de preconsolidação do solo (σ_p) a topologia da RNA11 que obteve o melhor resultado foi composta por 10 neurônios e 9 repetições no processo de treinamento.

Da mesma forma que a relação entre os modelos RNA10 e RNA8, a adição das variáveis de independentes de entrada que correspondem às partículas finas do solo (silte e argila) os valores dos coeficientes de determinação (R^2) de RNA11 foram inferiores aos obtidos em RNA9 (Figura 40), obtendo-se 0,0838 para resistência do solo à penetração (Figura 42-a) e 0,2996 para pressão de preconsolidação do solo (Figura 41-b), classificando-se como a pior arquitetura dentre as consideradas neste estudo.

Figura 42 - Representação gráfica dos valores de RP e σ_p observados na literatura em relação aos estimados por redes neurais artificiais no modelo RNA11



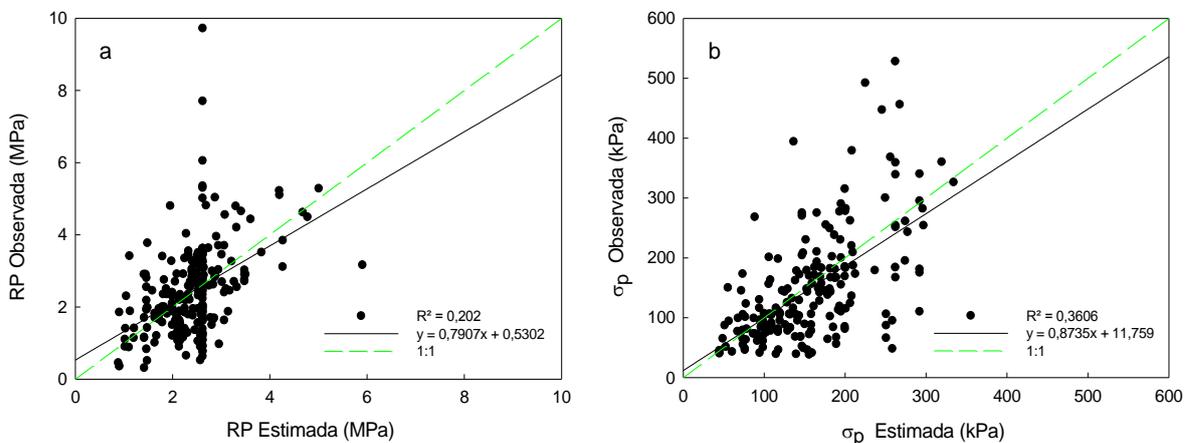
Fonte: Autor

4.2.12 Estimativa dos indicadores de capacidade de suporte de carga – RNA12

Compondo o modelo RNA12 estão apenas as variáveis texturais areia, silte e argila. Neste modelo as topologias que demonstraram maior capacidade preditiva foram a composta por 30 neurônios na camada escondida e 7 treinamentos para RP, e a composta por 50 neurônios e 9 treinamentos para σ_p .

Mesmo com valores de R^2 superiores ao modelo anterior (RNA11), sendo de 0,2020 para RNA12-RP (Figura 43-a) e 0,3606 para RNA12- σ_p (Figura 43-b), a capacidade preditiva do modelo RNA12 não é satisfatória de acordo com Smith (1986).

Figura 43 - Representação gráfica dos valores de RP e σ_p observados na literatura em relação aos estimados por redes neurais artificiais no modelo RNA12



Fonte: Autor

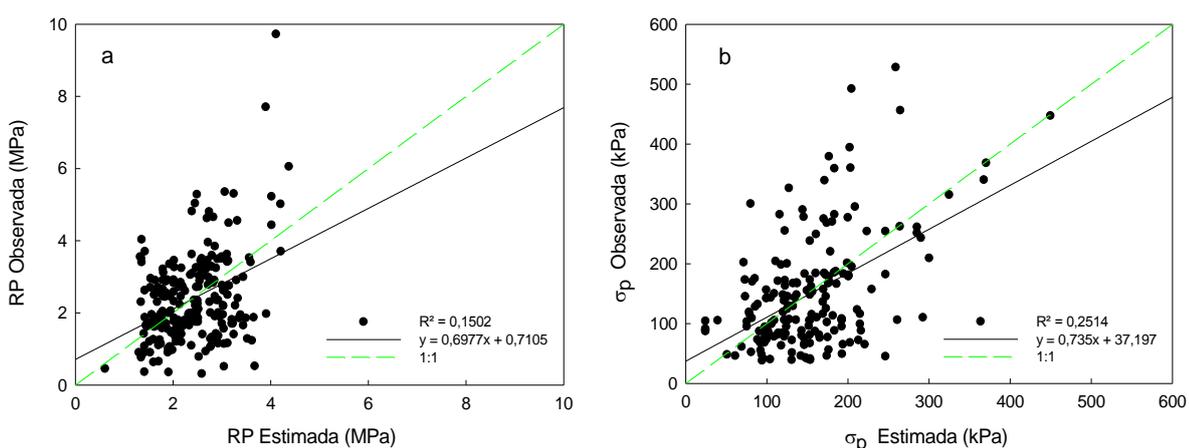
4.2.13 Estimativa dos indicadores de capacidade de suporte de carga – RNA13

O modelo RNA13 é composto pelas variáveis densidade do solo (D_s) e umidade volumétrica (θ), sendo estas as mesmas utilizadas no modelo não-linear desenvolvido por Busscher (BUSSCHER, 1990).

As Figuras 44-a e 44-b apresentam a relação gráfica entre os valores estimados e observados de resistência do solo à penetração (RP) e de pressão de preconsolidação do solo (σ_p), respectivamente, sendo que para a arquitetura RNA13 os melhores resultados preditivos foram obtidos utilizando-se, na camada escondida, 20 neurônios para estimativa de RP e 50 neurônios para σ_p , sendo 3 o número de repetições do processo de treinamento da RNA13-RP e 8 o número de repetições do processo de treinamento da RNA13- σ_p .

Observa-se que o ajustamento dos valores obtidos na literatura com os estimados pela RNA13 para RP (Figura 44-a) apresentam grande dispersão, visto que o coeficiente de determinação (R^2) foi de 0,1502. O ajustamento obtido pela RNA13 foi um pouco superior para a σ_p (Figura 44-b), o que correspondeu ao coeficiente de determinação igual a 0,2514.

Figura 44 - Representação gráfica dos valores de RP e σ_p observados na literatura em relação aos estimados por redes neurais artificiais no modelo RNA13



Fonte: Autor

4.2.14 Estimativa dos indicadores de capacidade de suporte de carga – RNA-FA1

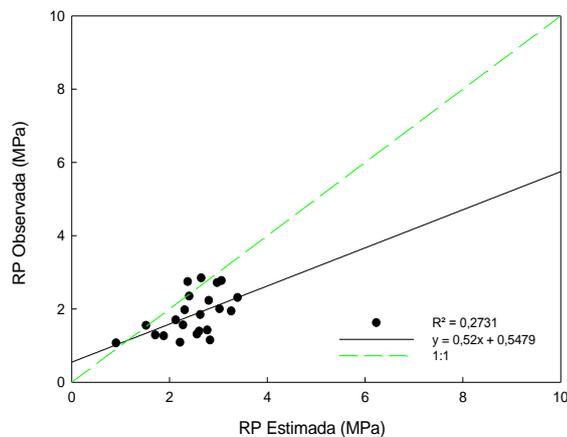
O modelo RNA-FA1, semelhante ao RNA13, é composto pelas variáveis de

entrada densidade do solo (D_s) e umidade volumétrica (θ), tendo como diferença o fato desta rede ter sido desenvolvida com dados de um solo com classe textural distinta (franco arenoso de uma única área produtiva sob diferentes manejos), de tal forma a poder compará-lo ao modelo não-linear desenvolvido por Busscher para a estimativa da resistência do solo à penetração (BUSSCHER, 1990).

A topologia da RNA-FA1 que melhor estimou a resistência do solo à penetração (RP), foi a constituída por 30 neurônios na camada intermediária e foi treinada 3 vezes.

Observa-se na Figura 45 que o ajustamento dos valores de RP obtidos na literatura com os estimados pela RNA-FA1 apresentam grande dispersão, visto que o coeficiente de determinação (R^2) foi de 0,2731, entretanto superior ao obtido pelo RNA13 desenvolvido para dados gerais, ou seja, sem distinção de classes texturais.

Figura 45 - Representação gráfica dos valores de RP observados na literatura em relação aos estimados por redes neurais artificiais no modelo RNA-FA1



Fonte: Autor

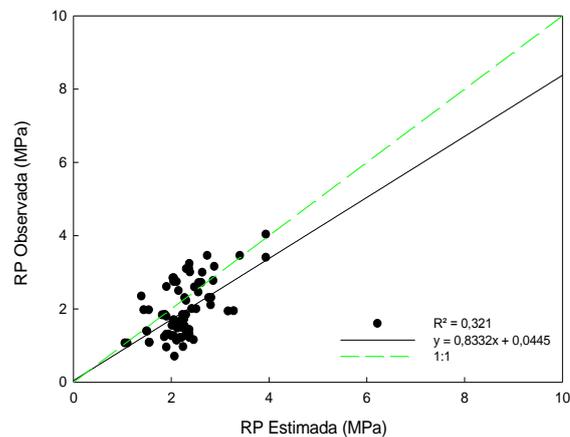
4.2.15 Estimativa dos indicadores de capacidade de suporte de carga – RNA-FA2

Assim como em RNA13 e RNA-FA1, as variáveis de entrada do modelo RNA-FA2 são densidade do solo (D_s) e umidade volumétrica (θ), sendo esta rede desenvolvida com dados de diferentes solos com a mesma classe textural (franco arenoso de diferentes localidades), de tal forma a poder compará-lo ao modelo não-linear desenvolvido por Busscher para a estimativa da resistência do solo à penetração (BUSSCHER, 1990).

A topologia da RNA-FA2 que melhor estimou a resistência do solo à penetração (RP), foi a constituída por 30 neurônios na camada intermediária e foi treinada 3 vezes.

Observa-se na Figura 46 que o ajustamento dos valores de RP obtidos na literatura com os estimados pela RNA-FA2 apresentam grande dispersão, visto que o coeficiente de determinação (R^2) foi de 0,3210, entretanto superior aos obtido por RNA13 desenvolvido para dados gerais, e por RNA-FA1 onde o mesmo tipo de solo esta sujeito a diferentes manejos agrícolas.

Figura 46 - Representação gráfica dos valores de RP observados na literatura em relação aos estimados por redes neurais artificiais no modelo RNA-FA2



Fonte: Autor

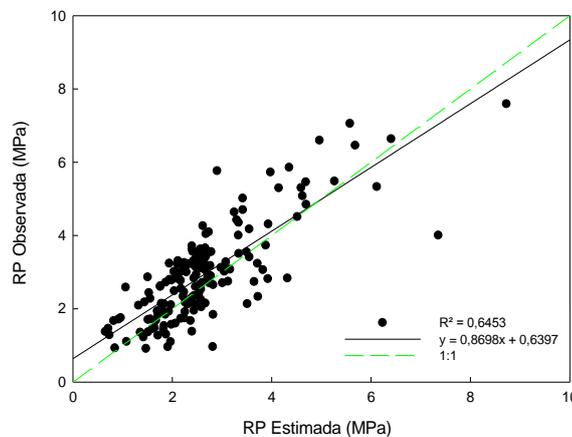
4.2.16 Estimativa dos indicadores de capacidade de suporte de carga – RNA-MA

Da mesma forma que RNA13, RNA-FA1 e RNA-FA2 as variáveis de entrada do modelo RNA-MA são densidade do solo (D_s) e umidade volumétrica (θ), sendo esta rede desenvolvida com dados de solo do tipo Muito Argiloso de uma mesma propriedade e exposto ao mesmo manejo, de tal forma a poder compará-lo ao modelo não-linear desenvolvido por Busscher para a estimativa da resistência do solo à penetração (BUSSCHER, 1990).

A topologia da RNA-MA que melhor estimou a resistência do solo à penetração (RP), foi a constituída por 10 neurônios na camada intermediária e foi treinada 3 vezes.

Observa-se na Figura 47 que o ajustamento dos valores de RP obtidos na literatura com os estimados pela RNA-MA é superior aos obtidos anteriormente com as mesmas variáveis independentes de entrada, visto que o coeficiente de determinação (R^2) foi de 0,6453, sendo aproximadamente 4 vezes maior ao obtido por RNA13 desenvolvido para dados gerais, e o dobro do obtido por RNA-FA2 onde os dados eram de um mesmo tipo de solo porém de diferentes localidades.

Figura 47 - Representação gráfica dos valores de RP observados na literatura em relação aos estimados por redes neurais artificiais no modelo RNA-MA



Fonte: Autor

4.3 VALORES ESTIMADOS POR MÁQUINAS DE VETORES DE SUPORTE (MVS)

Nesta seção são apresentados os resultados das FTPs das propriedades físico-mecânicas que se caracterizam por estimar a capacidade de suporte de carga do solo agrícola (resistência à penetração e pressão de preconsolidação) obtidos para cada um dos treze conjuntos de dados sem distinção de classe textural, e outros três conjuntos com classe textural distintas, através de Máquinas de Vetores de Suporte (MVS).

Foram testadas dezesseis modelos de máquinas de vetores de suporte (MVS1, MVS2, MVS3, MVS4, MVS5, MVS6, MVS7, MVS8, MVS9, MVS10, MVS11, MVS12, MVS13, MVS-FA1, MVS-FA2 e MVS-MA). Cada uma dessas máquinas de vetores de suporte é composta de diferentes entradas (Tabela 4), tendo como saídas a resistência à penetração (RP) e a pressão de preconsolidação (σ_p),

estimadas separadamente. A arquitetura entre elas foi a mesma (epsilon-SVR), sendo modificada somente a topologia. Cada topologia utilizada variou além das variáveis independentes de entrada e as variáveis dependentes de saída, a função kernel (Linear, Polinomial de 2º e 3º graus, *Radial Basis Function* – RBF e Sigmoidal) e os parâmetros C (0, 50, 100 e 150) e γ (ajustado a cada simulação).

A seguir são apresentados graficamente os resultados da melhor topologia para cada uma das MVS estudadas, sendo apresentados também os respectivos coeficientes de determinação.

4.3.1 Estimativa dos indicadores de capacidade de suporte de carga – MVS1

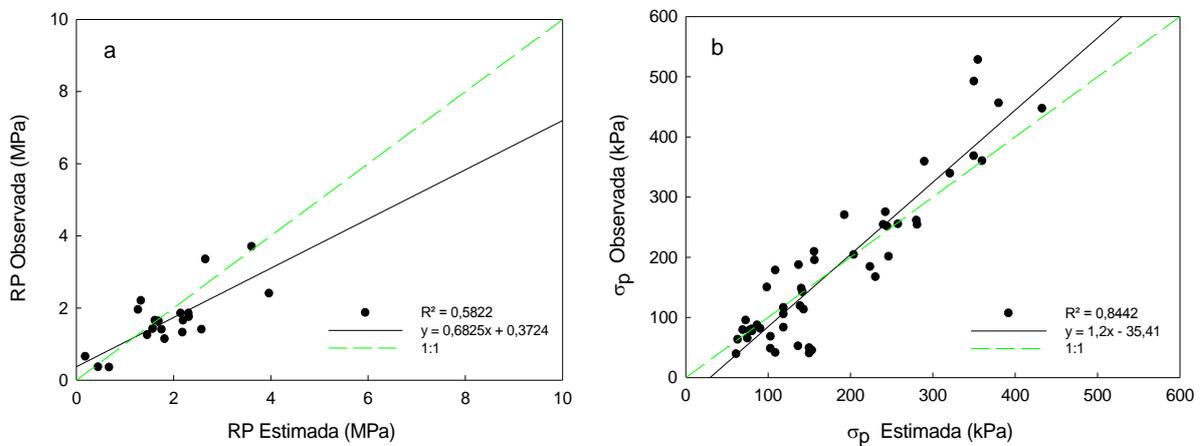
A seguir, na Figura 48, são apresentados os gráficos que ilustram a correlação entre os valores observados e estimados de resistência do solo à penetração (Figura 48-a) e de pressão de preconsolidação do solo (Figura 48-b).

A topologia da MVS1 que melhor estimou a resistência do solo à penetração (RP), foi a em que se utilizou a função kernel RBF e os valores para os parâmetros C e γ iguais a 100 e 160, respectivamente. Para a estimativa da pressão de preconsolidação do solo (σ_p) a topologia da MVS1 que obteve o melhor resultado também utilizou a função kernel Polinomial de 3º grau e os valores para o parâmetros C igual a 100 e γ igual a 0 (zero).

Observa-se que o ajustamento dos valores obtidos na literatura com os estimados pela MVS1, para RP (Figura 48-a) apresentam certa dispersão, entretanto, a reta representa os dados a um nível regular, visto que o coeficiente de determinação R^2 foi de 0,5822.

O ajustamento obtido pela MVS1 foi bem superior para a σ_p (Figura 48-b), apesar da reta originada pela FTP não possuir um ângulo de tão próximo de 45º como o ocorrido com RNA1(Figura 32-b), o que correspondeu ao coeficiente de determinação igual a 0,8442.

Figura 48 - Representação gráfica dos valores de RP e σ_p observados na literatura em relação aos estimados por máquinas de vetores de suporte no modelo MVS1



Fonte: Autor

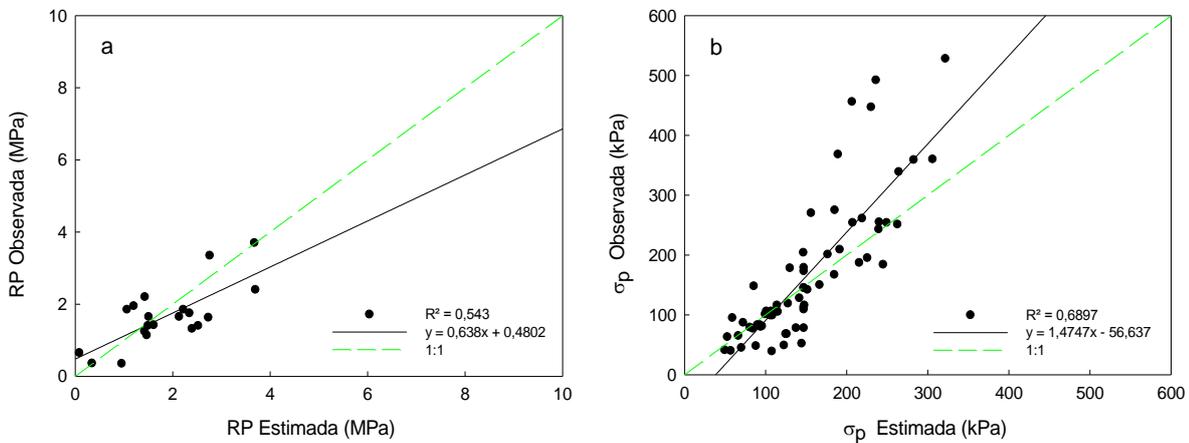
4.3.2 Estimativa dos indicadores de capacidade de suporte de carga – MVS2

As Figuras 49-a e 49-b apresentam a relação gráfica entre os valores estimados e observados de resistência do solo à penetração (RP) e de pressão de preconsolidação do solo (σ_p), respectivamente.

Para a arquitetura MVS2 os melhores resultados preditivos foram obtidos utilizando-se a função kernel RBF tanto para estimativa de RP quanto para σ_p , sendo C igual a 100 e γ igual a 15 os parâmetros da função kernel para MVS2-RP e C igual a 100 e γ igual a 20 os parâmetros da função kernel para MVS2- σ_p .

Os valores dos coeficientes de determinação (R^2) foram inferiores aos obtidos em MVS1, visto que MVS2 obteve 0,5430 para resistência do solo à penetração (Figura 49-a) e 0,6897 para pressão de preconsolidação do solo (Figura 49-b), podendo-se observar nesta última uma inclinação na reta gerada ainda maior àquela apresentada no modelo anterior (MVS1- σ_p). Estes resultados verificam a importância do teor de matéria orgânica (MO) para os índices de capacidade de suporte de carga dos solos e reforçam os resultados de Ribon e Tavares Filho (2008) que citam a MO como variável de entrada que contribui efetivamente para estimar a resistência do solo à penetração (RP) e com Mazurana (2011) que obteve resultado aceitável utilizando apenas MO para estimar a pressão de preconsolidação do solo (σ_p).

Figura 49 - Representação gráfica dos valores de RP e σ_p observados na literatura em relação aos estimados por máquinas de vetores de suporte no modelo MVS2



Fonte: Autor

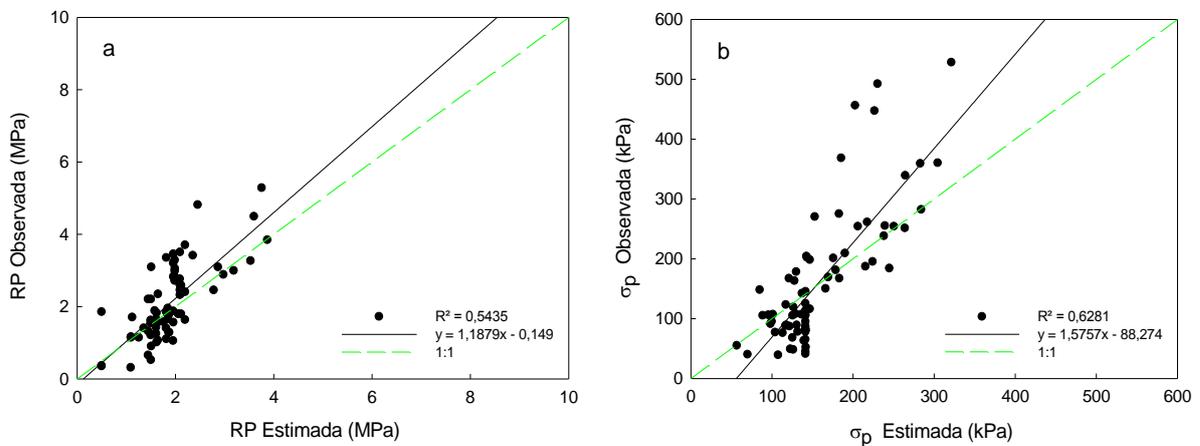
4.3.3 Estimativa dos indicadores de capacidade de suporte de carga – MVS3

Na MVS3, dentre as topologias utilizadas no estudo, as que demonstraram maior capacidade preditiva foram a composta pela a função kernel RBF e os parâmetros C igual a 100 e γ igual a 0 (zero) para RP , e a composta pela a função kernel RBF e os parâmetros C igual a 100 e γ igual a 20 para σ_p .

Pode-se notar (Figura 50-a) que o modelo MVS3- RP , diferente dos vistos anteriormente, apresenta uma reta com inclinação um pouco mais próxima a da reta 1:1, apesar de seu coeficiente de determinação (0,5435) ser muito próximo ao obtido no modelo MVS2- RP .

É possível observar na Figura 50-b, que o coeficiente de determinação R^2 para MVS3- σ_p (0,6281) foi inferior aos obtidos em MVS1- σ_p e MVS2- σ_p , de forma a se concluir que a variável de entrada matéria orgânica (MO) exerce menor influência que as variáveis de entrada limites de liquidez (LL) e limite de plasticidade (LP) para a estimativa da pressão de preconsolidação do solo (σ_p) por MVS, sendo que este resultado pode ser explicado segundo Mazurana (2011) e Mentges (2010) que relacionam os limites de consistência com indicadores da capacidade de suporte de carga dos solos, porém, também afetados pelo conteúdo de matéria orgânica do solo nas camadas superficiais.

Figura 50 - Representação gráfica dos valores de RP e σ_p observados na literatura em relação aos estimados por máquinas de vetores de suporte no modelo MVS3



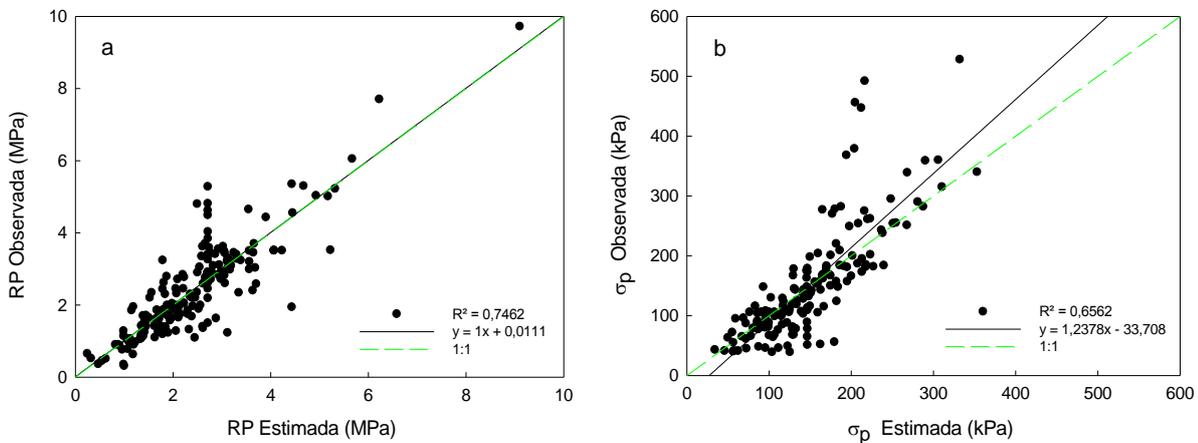
Fonte: Autor

4.3.4 Estimativa dos indicadores de capacidade de suporte de carga – MVS4

A topologia do modelo MVS4 que apresentou melhor capacidade preditiva para resistência do solo à penetração (RP) foi a que utilizou a função kernel RBF e os valores para os parâmetros C e γ iguais a 100 e 10, respectivamente. Para a estimativa da pressão de preconsolidação do solo (σ_p) a topologia da MVS4 que obteve o melhor resultado foi a de função kernel RBF e os parâmetros C igual a 100 e γ igual a 30.

Na Figura 51, são apresentados os gráficos que ilustram a correlação entre os valores observados e estimados de resistência do solo à penetração e de pressão de preconsolidação do solo. Observa-se que o ajustamento dos valores obtidos na literatura com os estimados pela MVS4, para RP (Figura 51-a) apresentam pouca dispersão, visto que o coeficiente de determinação R^2 foi de 0,7462, valor superior aos modelos anteriores, além de apresentar uma reta com inclinação bem próxima a da reta 1:1. O ajustamento obtido pela MVS4 foi superior a MVS para a σ_p (Figura 51-b), o que correspondeu ao coeficiente de determinação (R^2) igual a 0,6562. Apesar de apresentar menos variáveis de entrada, este aporte no coeficientes de determinação (R^2), provavelmente se deu em função do maior banco de dados obtido para o treinamento do modelo.

Figura 51 - Representação gráfica dos valores de RP e σ_p observados na literatura em relação aos estimados por máquinas de vetores de suporte no modelo MVS4



Fonte: Autor

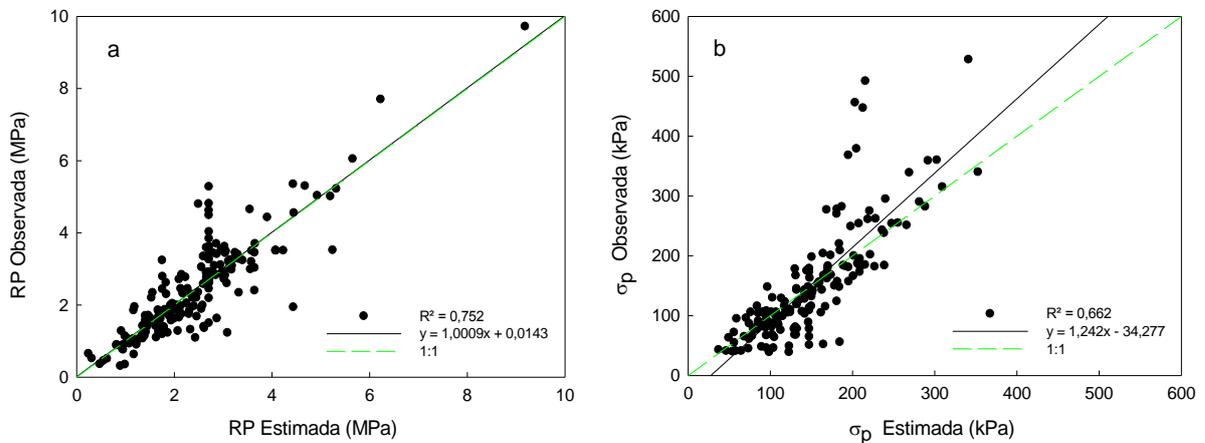
4.3.5 Estimativa dos indicadores de capacidade de suporte de carga – MVS5

No modelo MVS5, a estimativa da resistência do solo à penetração (RP) obteve o melhor resultado ao se utilizar a topologia constituída pela função kernel RBF e os parâmetros C igual a 100 e γ igual a 10. A topologia da MVS5 que obteve o melhor resultado para a estimativa da pressão de preconsolidação do solo (σ_p) foi a composta pela função kernel RBF e os parâmetros C igual a 100 e γ igual a 35.

As Figuras 52-a e 52-b apresentam a relação gráfica entre os valores estimados e observados de resistência do solo à penetração (RP) e de pressão de preconsolidação do solo (σ_p), respectivamente.

Nota-se que o ajustamento dos valores obtidos na literatura com os estimados pela MVS5-RP (Figura 52-a) foram ainda melhores que os modelos anteriores, visto que o coeficiente de determinação (R^2) foi de 0,7520, além de apresentar uma reta que quase se sobrepõe a reta 1:1. O ajustamento obtido pela MVS5- σ_p (Figura 52-b) foi razoável e superior aos modelos MVS3- σ_p e MVS4- σ_p , apresentando coeficiente de determinação (R^2) igual a 0,6620, podendo ser considerado uma boa opção de estimativa, visto que utiliza um número reduzido de variáveis independentes de entrada em sua arquitetura.

Figura 52 - Representação gráfica dos valores de RP e σ_p observados na literatura em relação aos estimados por máquinas de vetores de suporte no modelo MVS5



Fonte: Autor

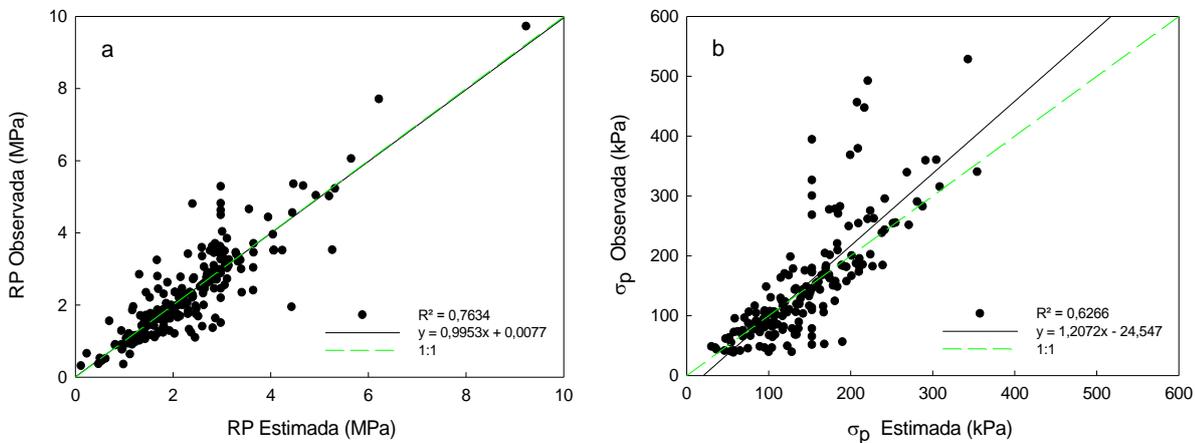
4.3.6 Estimativa dos indicadores de capacidade de suporte de carga – MVS6

Na MVS6 as topologias que demonstraram maior capacidade preditiva foram a composta pela função kernel RBF e os parâmetros C igual a 100 e γ igual a 10 para RP, e a composta pela função kernel RBF e os parâmetros C igual a 100 e γ igual a 35 para σ_p .

Pode-se notar (Figura 53-a) que o modelo MVS6-RP, da mesma forma que foi visto anteriormente (MVS5-RP), apresenta uma reta quase em sobreposição a reta 1:1, apresentando um coeficiente de determinação de 0,7634, sendo este o maior valor obtido entre os modelos já vistos para estimativa da resistência do solo à penetração (RP), e bem próximo ao 0,80 considerado por Smith (1986) como uma forte correlação.

É possível observar na Figura 53-b, que o coeficiente de determinação R^2 para MVS6- σ_p (0,6266) foi inferior aos obtidos anteriormente, diferente do que ocorreu com a MVS-RP, de forma a se deduzir que a variável de entrada densidade de partícula (D_p) exerce forte influência para a estimativa da pressão de preconsolidação. Como já citado anteriormente, os valores de densidade de partícula (D_p) são fortemente influenciados pelo teor de matéria orgânica (REICHARDT, 1975).

Figura 53 - Representação gráfica dos valores de RP e σ_p observados na literatura em relação aos estimados por máquinas de vetores de suporte no modelo MVS6



Fonte: Autor

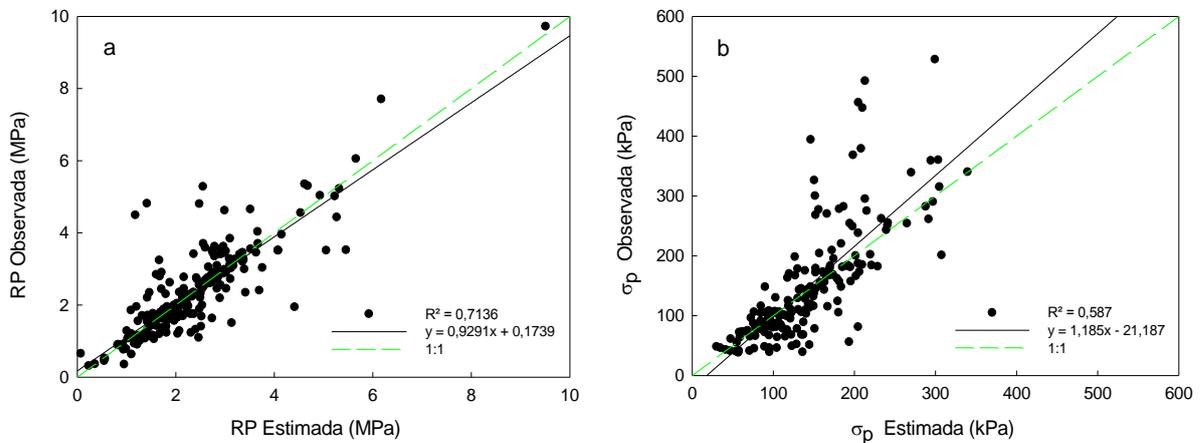
4.3.7 Estimativa dos indicadores de capacidade de suporte de carga – MVS7

As Figuras 54-a e 54-b apresentam a relação gráfica entre os valores estimados e observados de resistência do solo à penetração (RP) e de pressão de preconsolidação do solo (σ_p), respectivamente.

O modelo MVS7 diferencia-se do anterior pela variável Silte + Argila que é a soma das duas variáveis apresentadas separadamente no modelo MVS6. Para a arquitetura MVS7 os melhores resultados preditivos foram obtidos utilizando-se a função kernel RBF tanto para estimativa da resistência do solo à penetração (RP) quanto para pressão de preconsolidação (σ_p), sendo C igual a 100 e γ igual a 15 para o processo de treinamento da MVS7-RP e C igual a 100 e γ igual a 40 para processo de treinamento da MVS7- σ_p .

Nota-se que com a soma das variáveis de entrada que correspondem às partículas finas do solo (silte e argila) os valores dos coeficientes de determinação (R^2) foram inferiores aos obtidos em MVS6, visto que MVS7 obteve 0,7136 para resistência do solo à penetração (Figura 54-a) e 0,5870 para pressão de preconsolidação do solo (Figura 54-b), observando-se ainda uma inclinação na reta gerada já não tão próxima a reta 1:1, diferente do que foi visto na MVS6 (Figura 53).

Figura 54 - Representação gráfica dos valores de RP e σ_p observados na literatura em relação aos estimados por máquinas de vetores de suporte no modelo MVS7



Fonte: Autor

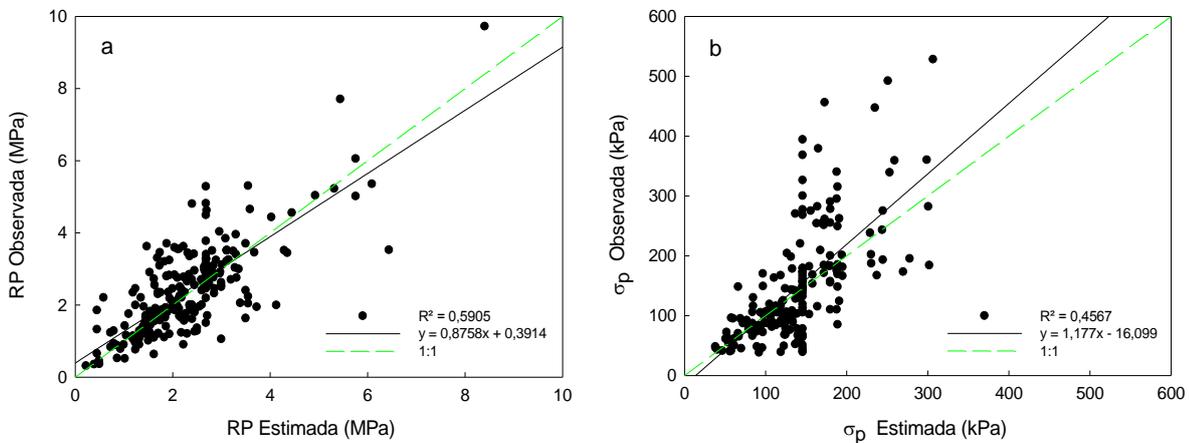
4.3.8 Estimativa dos indicadores de capacidade de suporte de carga – MVS8

A topologia da MVS8 que melhor estimou a resistência do solo à penetração (RP), foi a constituída pela função kernel RBF e os parâmetros C igual a 100 e γ igual a 5. Para a estimativa da pressão de preconsolidação do solo (σ_p) a topologia da MVS8 que obteve o melhor resultado foi a que utilizou a função kernel RBF e os parâmetros C igual a 100 e γ igual a 20.

A seguir, na Figura 55, são apresentados os gráficos que ilustram a correlação entre os valores observados e os estimados de resistência do solo à penetração (Figura 55-a) e de pressão de preconsolidação do solo (Figura 55-b).

Observa-se que o ajustamento dos valores obtidos na literatura com os estimados pela MVS8 para RP apresentam uma maior dispersão dos pontos, visto que o coeficiente de determinação (R^2) foi de 0,5905. O ajustamento obtido pela MVS8 foi ainda inferior para a σ_p , o que correspondeu ao coeficiente de determinação igual a 0,4567. Visto que neste modelo (MVS8) a umidade volumétrica do solo (θ) foi a variável de entrada excluída, os baixos valores de R^2 demonstram a importância do conteúdo de água no solo para a capacidade de suporte de carga deste, assim como ocorreu em RNA8 concordando com estudos de vários autores (AJAYI, 2010; BUSSCHER, 1990; DEBIASE, 2008; DIAS JUNIOR, 2004; GUBIANI, 2012; MOSADDEGHI, 2006; RIBON; TAVARES FILHO, 2008).

Figura 55 - Representação gráfica dos valores de RP e σ_p observados na literatura em relação aos estimados por máquinas de vetores de suporte no modelo MVS8



Fonte: Autor

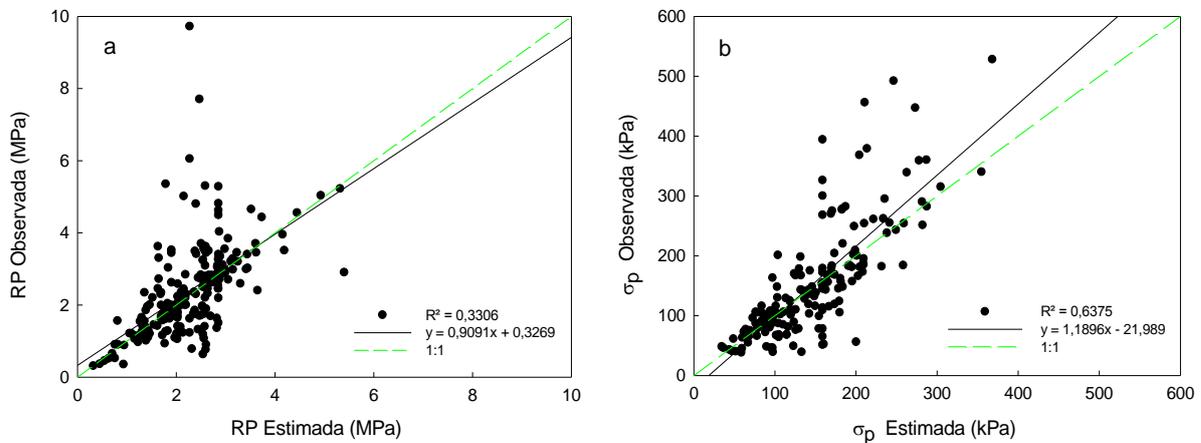
4.3.9 Estimativa dos indicadores de capacidade de suporte de carga – MVS9

O modelo MVS9 é composto pelas frações granulométricas (areia, silte e argila) e pela umidade volumétrica (θ). Neste modelo as topologias que demonstraram maior capacidade preditiva foram a composta pela função kernel RBF e os parâmetros C igual a 100 e γ igual a 20 para RP, e a composta pela função kernel RBF e os parâmetros C igual a 100 e γ igual a 40 para σ_p .

Observa-se (Figura 56-a) que o ajustamento dos valores obtidos na literatura com os estimados pela MVS9, para resistência do solo à penetração (RP), apresentam uma dispersão muito acentuada, visto que o coeficiente de determinação (R^2) foi de 0,3306, enquanto o ajustamento obtido pela MVS9 para a σ_p foi bem superior, o que correspondeu ao coeficiente de determinação igual a 0,6375 (Figura 56-b).

Estes resultados comparados ao modelo anterior (MVS8) apontam que a variável densidade do solo (D_s) apesar de ser de grande importância para a determinação de ambos os indicadores de capacidade de suporte de carga do solo (RP e σ_p), exerce maior influência na obtenção da resistência à penetração, enquanto a pressão de preconsolidação é mais suscetível à variação do conteúdo de água no solo (θ).

Figura 56 - Representação gráfica dos valores de RP e σ_p observados na literatura em relação aos estimados por máquinas de vetores de suporte no modelo MVS9



Fonte: Autor

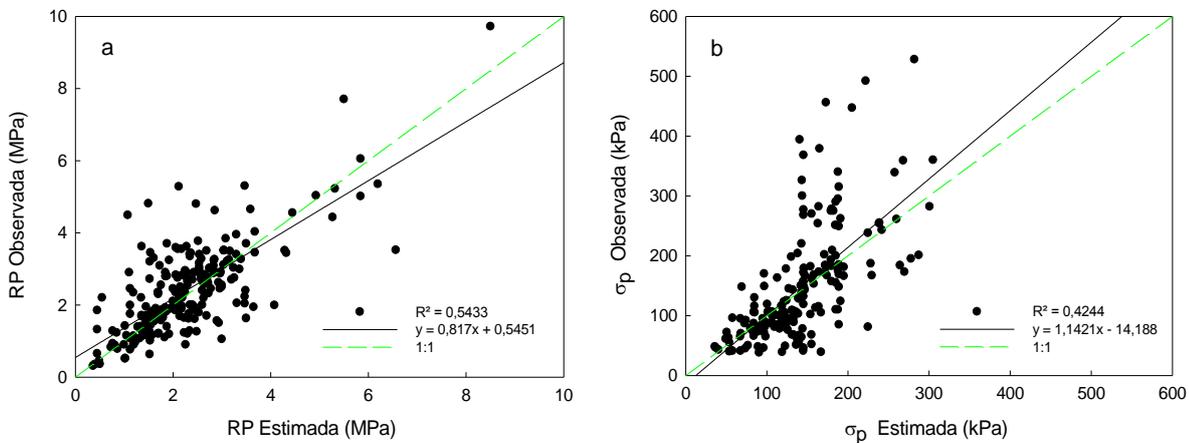
4.3.10 Estimativa dos indicadores de capacidade de suporte de carga – MVS10

A arquitetura do modelo MVS10 tem em sua camada de entrada as frações granulométricas e a densidade do solo (D_p), diferenciando-se do modelo MVS8 por possuir as frações silte e argila somadas, de forma a representarem uma única variável de entrada.

A topologia da MVS10 que melhor estimou a resistência do solo à penetração (RP), foi a constituída pela função kernel RBF e os parâmetros C igual a 100 e γ igual a 10. Para a estimativa da pressão de preconsolidação do solo (σ_p) a topologia da MVS10 que obteve o melhor resultado também possuía a função kernel RBF e os parâmetro C igual a 100 diferenciando-se pelo parâmetro γ igual a 40.

Observou-se, assim como no modelo MVS7, que com a adição das variáveis de independentes de entrada que correspondem às partículas finas do solo (silte e argila) os valores dos coeficientes de determinação (R^2) de MVS10 foram inferiores aos obtidos em MVS8 (Figura 55), obtendo-se 0,5433 para resistência do solo à penetração (Figura 57-a) e 0,4244 para pressão de preconsolidação do solo (Figura 57-b).

Figura 57 - Representação gráfica dos valores de RP e σ_p observados na literatura em relação aos estimados por máquinas de vetores de suporte no modelo MVS10



Fonte: Autor

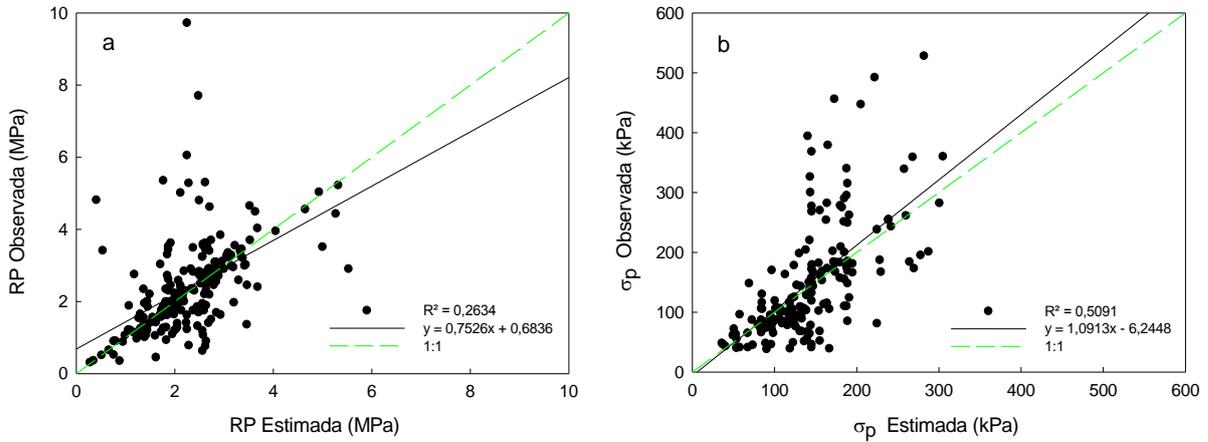
4.3.11 Estimativa dos indicadores de capacidade de suporte de carga – MVS11

O modelo MVS11 tem em sua arquitetura a camada de entrada composta pelas frações granulométricas e a umidade volumétrica, diferindo do modelo MVS9 pelo fato das frações silte e argila somadas representarem uma única variável de entrada.

A topologia da MVS11 que apresentou melhor capacidade preditiva para resistência do solo à penetração (RP), foi a composta pela função kernel RBF e os parâmetros C igual a 100 e γ igual a 30. Para a estimativa da pressão de preconsolidação do solo (σ_p) a topologia da MVS11 que obteve o melhor resultado foi composta pela função kernel RBF e os parâmetros C igual a 100 e γ igual a 45.

Da mesma forma que a relação entre os modelos MVS10 e MVS8, a adição das variáveis de independentes de entrada que correspondem às partículas finas do solo (silte e argila) os valores dos coeficientes de determinação (R^2) de MVS11 foram inferiores aos obtidos em MVS9 (Figura 56), obtendo-se 0,2634 para resistência do solo à penetração (Figura 58-a) e 0,5091 para pressão de preconsolidação do solo (Figura 58-b).

Figura 58 - Representação gráfica dos valores de RP e σ_p observados na literatura em relação aos estimados por máquinas de vetores de suporte no modelo MVS11



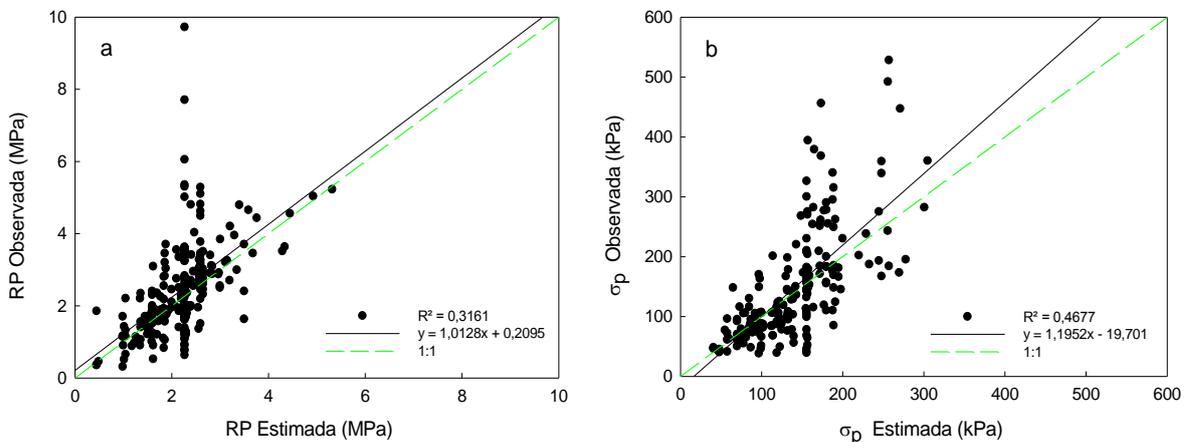
Fonte: Autor

4.3.12 Estimativa dos indicadores de capacidade de suporte de carga – MVS12

No modelo MVS12 estão apenas as variáveis texturais areia, silte e argila. Neste modelo as topologias que demonstraram maior capacidade preditiva foram compostas pela função kernel RBF e o parâmetro C igual a 100 tanto para RP quanto para σ_p , diferindo apenas em γ igual a 15 para RP, e γ igual a 1 para σ_p .

O valor do coeficiente de determinação R^2 foi superior ao modelo MVS11 apenas para resistência do solo à penetração sendo de 0,3161 para MVS12-RP (Figura 59-a), enquanto o modelo MVS12- σ_p (Figura 59-b) obteve R^2 de 0,4677.

Figura 59 - Representação gráfica dos valores de RP e σ_p observados na literatura em relação aos estimados por máquinas de vetores de suporte no modelo MVS12



Fonte: Autor

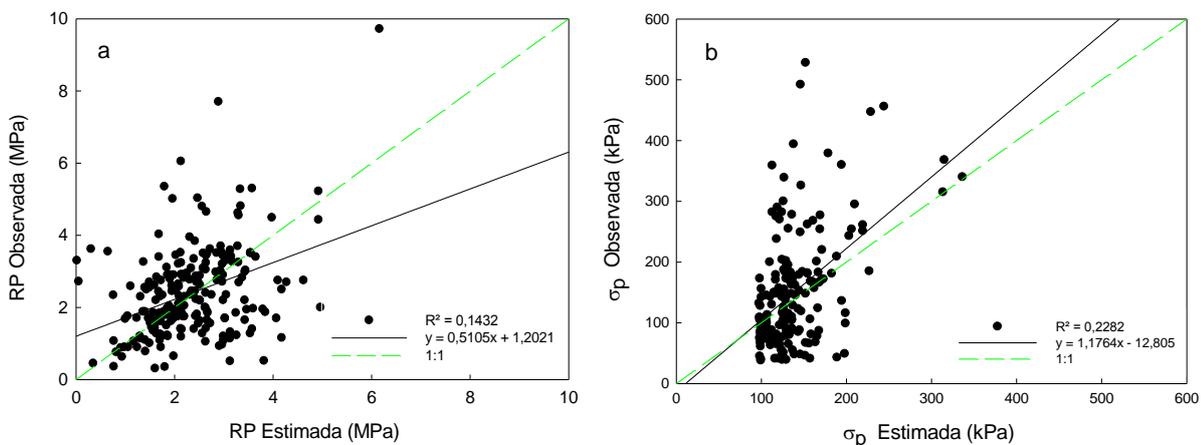
4.3.13 Estimativa dos indicadores de capacidade de suporte de carga – MVS13

O modelo MVS13 é composto pelas variáveis densidade do solo (D_s) e umidade volumétrica (θ), sendo estas as mesmas utilizadas no modelo não-linear desenvolvido por Busscher (BUSSCHER, 1990).

As Figuras 60-a e 60-b apresentam a relação gráfica entre os valores estimados e observados de resistência do solo à penetração (RP) e de pressão de preconsolidação do solo (σ_p), respectivamente, sendo que para a arquitetura MVS13 os melhores resultados preditivos foram obtidos utilizando-se a função kernel RBF e os parâmetros C igual a 100 e γ igual a 150 para estimativa de RP, e função kernel RBF e os parâmetros C igual a 100 e γ igual a 15 para o processo de treinamento da MVS13- σ_p .

Observa-se que o ajustamento dos valores obtidos na literatura com os estimados pela MVS13 para RP (Figura 60-a) apresentam grande dispersão, visto que o coeficiente de determinação (R^2) foi de 0,1432. O ajustamento obtido pela MVS13 foi um pouco superior para a σ_p (Figura 60-b), o que correspondeu ao coeficiente de determinação igual a 0,2282, classificando-se como a pior dentre as arquiteturas MVS consideradas neste estudo.

Figura 60 - Representação gráfica dos valores de RP e σ_p observados na literatura em relação aos estimados por máquinas de vetores de suporte no modelo MVS13



Fonte: Autor

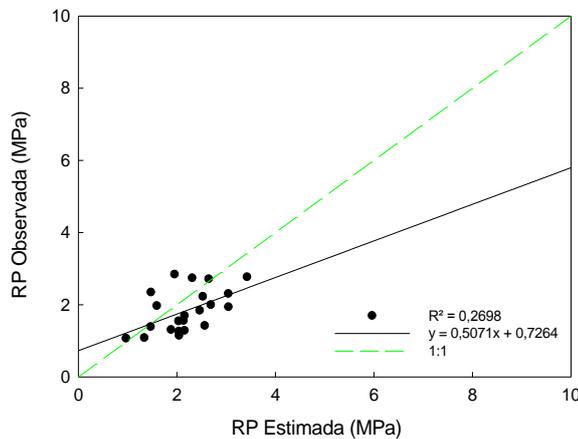
4.3.14 Estimativa dos indicadores de capacidade de suporte de carga – MVS-FA1

O modelo MVS-FA1, semelhante ao MVS13, é composto pelas variáveis de entrada densidade do solo (D_s) e umidade volumétrica (θ), tendo como diferença o fato desta MVS ter sido desenvolvida com dados de um solo com classe textural distinta (franco arenoso de uma única área produtiva sob diferentes manejos), de tal forma a poder compará-lo ao modelo não-linear desenvolvido por Busscher para a estimativa da resistência do solo à penetração (BUSSCHER, 1990).

A topologia da MVS-FA1 que melhor estimou a resistência do solo à penetração (RP), foi a constituída utilizando a função kernel Polinomial de 3º grau e os parâmetros C igual a 100 e γ igual a 4,6.

Observa-se na Figura 61 que o ajustamento dos valores de RP obtidos na literatura com os estimados pela MVS-FA1 apresentam grande dispersão, visto que o coeficiente de determinação (R^2) foi de 0,2698, entretanto superior ao obtido pelo MVS13 desenvolvido para dados gerais, ou seja, sem distinção de classes texturais.

Figura 61 - Representação gráfica dos valores de RP observados na literatura em relação aos estimados por redes neurais artificiais no modelo MVS-FA1



Fonte: Autor

4.3.15 Estimativa dos indicadores de capacidade de suporte de carga – MVS-FA2

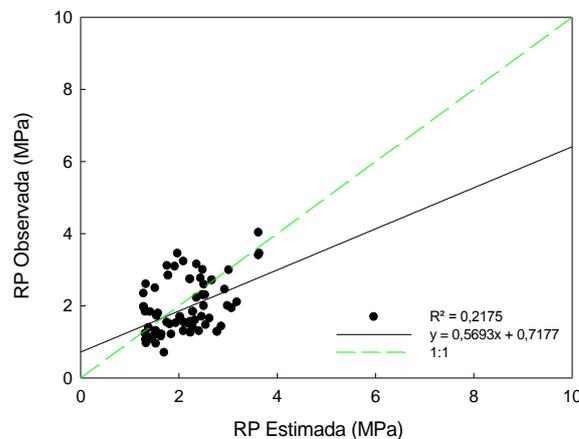
Da mesma forma que em MVS13 e MVS-FA1, as variáveis de entrada do modelo MVS-FA2 são densidade do solo (D_s) e umidade volumétrica (θ), sendo esta rede desenvolvida com dados de diferentes solos com a mesma classe textural

(franco arenoso de diferentes localidades), de tal forma a poder compará-lo ao modelo não-linear desenvolvido por Busscher para a estimativa da resistência do solo à penetração (BUSSCHER, 1990).

A topologia da RNA-FA2 que melhor estimou a resistência do solo à penetração (RP), foi a constituída pela função kernel RBF e os parâmetros C igual a 100 e γ igual a 0,9.

Observa-se na Figura 62 que o ajustamento dos valores de RP obtidos na literatura com os estimados pela MVS-FA2 apresentam grande dispersão, visto que o coeficiente de determinação (R^2) foi de 0,2175, entretanto superior aos obtido por MVS13 desenvolvido para dados gerais, e inferior a MVS-FA1 onde o mesmo tipo de solo esta sujeito a diferentes manejos agrícolas, porém é de uma mesma localidade geográfica.

Figura 62 - Representação gráfica dos valores de RP observados na literatura em relação aos estimados por redes neurais artificiais no modelo MVS-FA2



Fonte: Autor

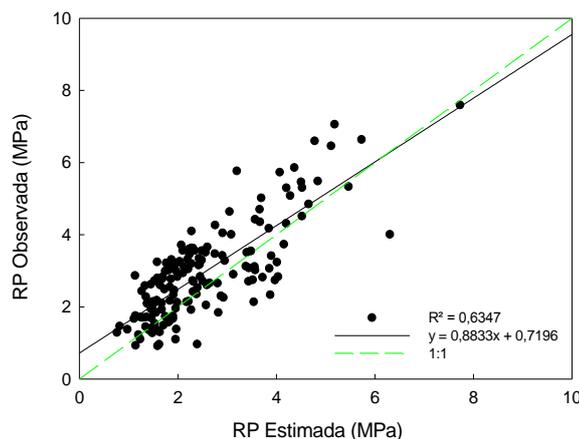
4.3.16 Estimativa dos indicadores de capacidade de suporte de carga – MVS-MA

Da mesma forma que MVS13, MVS-FA1 e MVS-FA2 as variáveis de entrada do modelo RNA-MA são densidade do solo (D_s) e umidade volumétrica (θ), sendo esta rede desenvolvida com dados de solo do tipo Muito Argiloso de uma mesma propriedade exposto ao mesmo manejo, de tal forma a poder compará-lo ao modelo não-linear desenvolvido por Busscher para a estimativa da resistência do solo à penetração (BUSSCHER, 1990).

A topologia da MVS-MA que melhor estimou a resistência do solo à penetração (RP), foi a constituída pela função kernel RBF e os parâmetros C igual a 100 e γ igual a 1,6.

Observa-se na Figura 63 que o ajustamento dos valores de RP obtidos na literatura com os estimados pela MVS-MA é superior aos obtidos anteriormente com as mesmas variáveis independentes de entrada, visto que o coeficiente de determinação (R^2) foi de 0,6347, sendo mais de 4 vezes maior ao obtido por MVS13 desenvolvido para dados gerais, aproximadamente 3 vezes maior ao obtido por MVS-FA2 onde os dados eram de um mesmo tipo de solo porém de diferentes localidades e mais que o dobro do obtido MVS-FA1 onde os dados eram de um solo de mesma área produtiva sujeito a diferentes manejos agrícolas.

Figura 63 - Representação gráfica dos valores de RP observados na literatura em relação aos estimados por redes neurais artificiais no modelo MVS-MA



Fonte: Autor

4.4 DESEMPENHO DOS MODELOS E METODOLOGIAS AVALIADAS

Para a análise comparativa foram construídas tabelas compostas por valores de índice de concordância (c), coeficiente de correlação (r), coeficiente de determinação (R^2) e índice de desempenho (id) das topologias que apresentaram melhores resultados nos métodos estudados, e do modelo de Busscher (1990). Resultados estimados de resistência do solo à penetração (RP) pelo modelo da Busscher foram utilizados para comparação com os demais modelos (RLM, RNA e MVS).

Com finalidade de comparar as estimativas de pressão de preconsolidação (σ_p), geradas pelos métodos em estudo, a um método bastante citado na bibliografia, é apresentada a análise comparativa ao método proposto por Dias Junior e Pierce (1995) que estima a pressão de preconsolidação utilizando um modelo processado em planilha eletrônica disponível em Severiano et al. (2011).

Também neste capítulo são apresentados gráficos que apresentam os valores de RP e σ_p estimados pelos métodos de regressão linear múltipla (RLM), redes neurais artificiais (RNA) e máquinas de vetores de suporte (MVS), sendo estes avaliados inicialmente de forma geral, e posteriormente separados por diferentes cenários que denotam classes texturais e manejos diferenciados de solo.

4.4.1 Desempenho dos modelos obtidos por RLM para dados gerais

A Tabela 24 apresenta os coeficiente de correlação (r), de determinação (R^2), índices de concordância (c) (WILLMOTT et al., 1981) e desempenho (id) (Tabela 9) sugeridos por Camargo e Sentelhas (1997), para os dados estimados de resistência do solo à penetração (RP) utilizando regressão linear múltipla (RLM) para as treze arquiteturas desenvolvidas para dados gerais (dados de classes texturais diversas).

Tabela 24 - Valores do coeficiente de correlação (r), coeficiente de determinação (R^2), índice de concordância (c), índice de desempenho (id) e a classe de desempenho qualitativo dos diferentes modelos de RLM para estimativa da resistência do solo à penetração (RP)

Modelo	c	r	R ²	id	Classe
RLM1-RP	0,81	0,68	0,46	0,55	Fraco
RLM2-RP	0,81	0,68	0,46	0,55	Fraco
RLM3-RP	0,67	0,53	0,28	0,36	Péssimo
RLM4-RP	0,61	0,40	0,16	0,24	Péssimo
RLM5-RP	0,60	0,40	0,16	0,24	Péssimo
RLM6-RP	0,42	0,20	0,04	0,08	Péssimo
RLM7-RP	0,33	0,13	0,02	0,04	Péssimo
RLM8-RP	0,43	0,23	0,05	0,10	Péssimo
RLM9-RP	0,18	0,05	0,00	0,01	Péssimo
RLM10-RP	0,34	0,14	0,02	0,05	Péssimo
RLM11-RP	0,14	0,01	0,00	0,00	Péssimo
RLM12-RP	0,22	0,16	0,03	0,04	Péssimo
RLM13-RP	0,22	0,11	0,01	0,02	Péssimo

Fonte: Autor

De modo geral, pode-se afirmar que o método de regressão linear múltipla (RLM) não apresentou um bom desempenho para estimar a resistência do solo à penetração, visto que as FTPs geradas a partir dos modelos RLM1-RP e RLM2-RP foram as que apresentaram o melhor desempenho, ainda assim classificado como “fraco”, ficando os demais modelos classificados como “péssimo”.

A Tabela 25 apresenta os índices de correlação (r), concordância (c) e desempenho (id), para os dados estimados de pressão de preconsolidação do solo (σ_p) utilizando regressão linear múltipla (RLM) para as treze arquiteturas desenvolvidas para dados gerais.

Tabela 25 - Valores do coeficiente de correlação (r), coeficiente de determinação (R^2), índice de concordância (c), índice de desempenho (id) e a classe de desempenho qualitativo dos diferentes modelos de RLM para estimativa da pressão de preconsolidação do solo (σ_p)

Modelo	c	r	R²	id	Classe
RLM1- σ_p	0,75	0,66	0,43	0,49	Muito Fraco
RLM2- σ_p	0,57	0,44	0,20	0,25	Péssimo
RLM3- σ_p	0,74	0,65	0,42	0,48	Muito Fraco
RLM4- σ_p	0,50	0,35	0,12	0,17	Péssimo
RLM5- σ_p	0,50	0,35	0,12	0,17	Péssimo
RLM6- σ_p	0,49	0,35	0,12	0,17	Péssimo
RLM7- σ_p	0,46	0,34	0,12	0,16	Péssimo
RLM8- σ_p	0,29	0,16	0,02	0,05	Péssimo
RLM9- σ_p	0,49	0,35	0,12	0,17	Péssimo
RLM10- σ_p	0,24	0,18	0,03	0,04	Péssimo
RLM11- σ_p	0,46	0,34	0,12	0,16	Péssimo
RLM12- σ_p	0,26	0,14	0,02	0,04	Péssimo
RLM13- σ_p	0,27	0,12	0,01	0,03	Péssimo

Fonte: Autor

O desempenho do método de regressão linear múltipla (RLM) foi ainda pior para pressão de preconsolidação do solo (σ_p), visto que as FTPs geradas a partir dos modelos RLM1- σ_p e RLM3- σ_p foram as que apresentaram o melhor desempenho, classificado como “muito fraco”, sendo estes os dois modelos que apresentam em sua arquitetura a matéria orgânica (MO) como variável independente de entrada, concordando com Mazurana (2011) que afirmou que o conteúdo de matéria orgânica no solo afeta positivamente a capacidade de suporte de carga. Os demais modelos classificaram-se como “péssimo”.

Desta forma, pode-se afirmar que o método de regressão linear múltipla (RLM) não se adequou a estimar a capacidade de suporte de carga do solo nas condições determinadas por este estudo.

4.4.2 Desempenho dos modelos obtidos por RNA para dados gerais

A capacidade preditiva das RNA para estimar a resistência do solo à penetração é apresentada na Tabela 26, através do indicador de desempenho (id). Também são apresentados o índice de concordância e os coeficientes de correlação (r) e de determinação (R^2).

Tabela 26 - Valores do coeficiente de correlação (r), coeficiente de determinação (R^2), índice de concordância (c), índice de desempenho (id) e a classe de desempenho qualitativo dos diferentes modelos de RNA para estimativa da resistência do solo à penetração (RP)

Modelo	c	r	R^2	id	Classe
RNA1-RP	0,88	0,83	0,68	0,73	Bom
RNA2-RP	0,89	0,81	0,66	0,72	Bom
RNA3-RP	0,90	0,82	0,67	0,74	Bom
RNA4-RP	0,91	0,84	0,70	0,76	Muito Bom
RNA5-RP	0,91	0,85	0,73	0,78	Muito Bom
RNA6-RP	0,89	0,81	0,65	0,72	Bom
RNA7-RP	0,87	0,78	0,61	0,68	Bom
RNA8-RP	0,83	0,71	0,50	0,59	Fraco
RNA9-RP	0,59	0,42	0,17	0,25	Péssimo
RNA10-RP	0,83	0,70	0,49	0,58	Fraco
RNA11-RP	0,48	0,29	0,08	0,14	Péssimo
RNA12-RP	0,60	0,45	0,20	0,27	Péssimo
RNA13-RP	0,59	0,39	0,15	0,23	Péssimo

Fonte: Autor

Pode-se verificar que para a estimativa da resistência à penetração, as redes neurais artificiais (RNA) obtiveram, de um modo geral, uma boa classificação. Dentre os modelos deste estudo o RNA5-RP, contendo como variáveis de entrada as frações granulométricas (areia, silte e argila), a densidade de partícula (D_p), a densidade do solo (D_s) e a umidade volumétrica (θ), foi o que obteve o maior índice de desempenho (0,78) classificado como “muito bom”. Este resultado concorda com Santos et al. (2012) que afirmaram que RNA pode ser utilizada para prever a resistência à penetração do solo.

A Tabela 27 apresenta os índices de correlação (r), concordância (c) e desempenho (id), para os dados estimados de pressão de preconsolidação do solo (σ_p) utilizando redes neurais artificiais (RNA) em treze arquiteturas desenvolvidas para dados gerais, ou seja, para um banco de composto diferentes tipos de solo.

Tabela 27 - Valores do coeficiente de correlação (r), coeficiente de determinação (R^2), índice de concordância (c), índice de desempenho (id) e a classe de desempenho qualitativo dos diferentes modelos de RNA para estimativa da pressão de preconsolidação do solo (σ_p)

Modelo	c	r	R²	id	Classe
RNA1- σ_p	0,97	0,94	0,88	0,91	Ótimo
RNA2- σ_p	0,95	0,92	0,84	0,88	Ótimo
RNA3- σ_p	0,96	0,92	0,85	0,88	Ótimo
RNA4- σ_p	0,90	0,81	0,66	0,73	Bom
RNA5- σ_p	0,90	0,82	0,67	0,74	Bom
RNA6- σ_p	0,86	0,76	0,57	0,65	Regular
RNA7- σ_p	0,79	0,69	0,48	0,55	Fraco
RNA8- σ_p	0,81	0,68	0,46	0,55	Fraco
RNA9- σ_p	0,83	0,71	0,50	0,59	Fraco
RNA10- σ_p	0,70	0,60	0,36	0,42	Muito Fraco
RNA11- σ_p	0,68	0,55	0,30	0,37	Péssimo
RNA12- σ_p	0,74	0,60	0,36	0,44	Muito Fraco
RNA13- σ_p	0,68	0,50	0,25	0,34	Péssimo

Fonte: Autor

De maneira geral, as redes neurais artificiais (RNA), também apresentaram boa capacidade preditiva para a pressão de preconsolidação do solo (σ_p), obtendo índices de desempenho superiores aos de estimativa de RP. O mais alto índice de desempenho (id) foi obtido utilizando todas as variáveis de entrada consideradas neste estudo, alcançando o valor de 0,91 para RNA1- σ_p , classificando-se como “ótimo”.

Outros dois modelos também classificaram-se como “ótimo” ambos com índice de desempenho igual a 0,88, sendo RNA2- σ_p obtido sem a variável de entrada matéria orgânica (MO) e RNA3- σ_p obtido sem as variáveis de entrada limite de liquidez (LL) e limite de plasticidade (LP).

4.4.3 Desempenho dos modelos obtidos por MVS para dados gerais

Os valores do coeficiente de correlação, coeficiente de determinação, índice de concordância, índice e classificação do desempenho, obtidos a partir da comparação entre os valores de resistência do solo à penetração observados, com os estimados pelas FPTs desenvolvidas para o banco de dados geral com a utilização de máquinas de vetores de suporte (MVS) são apresentados na Tabela 28.

Tabela 28 - Valores do coeficiente de correlação (r), coeficiente de determinação (R^2), índice de concordância (c), índice de desempenho (id) e a classe de desempenho qualitativo dos diferentes modelos de MVS para estimativa da resistência do solo à penetração (RP)

Modelo	c	r	R²	id	Classe
MVS1-RP	0,85	0,76	0,58	0,65	Regular
MVS2-RP	0,84	0,74	0,54	0,62	Regular
MVS3-RP	0,79	0,74	0,54	0,58	Fraco
MVS4-RP	0,92	0,86	0,75	0,80	Muito Bom
MVS5-RP	0,92	0,87	0,75	0,80	Muito Bom
MVS6-RP	0,93	0,87	0,76	0,81	Muito Bom
MVS7-RP	0,92	0,84	0,71	0,77	Muito Bom
MVS8-RP	0,87	0,77	0,59	0,67	Bom
MVS9-RP	0,70	0,58	0,33	0,40	Péssimo
MVS10-RP	0,85	0,74	0,54	0,63	Regular
MVS11-RP	0,68	0,51	0,26	0,35	Péssimo
MVS12-RP	0,66	0,56	0,32	0,37	Péssimo
MVS13-RP	0,62	0,38	0,14	0,24	Péssimo

Fonte: Autor

Para a estimativa da resistência à penetração, nota-se que as máquinas de vetores de suporte (MVS) obtiveram, em algumas arquiteturas, uma boa classificação. Dentre os modelos deste estudo o MVS6-RP, contendo como variáveis de entrada as frações granulométricas (areia, silte e argila), a densidade do solo (D_s) e a umidade volumétrica (θ), foi o que obteve o maior índice de desempenho (0,81) classificado como “muito bom”, corroborando com CANARACHE (1990) que afirma que a RP é afetada pela textura, pela densidade do solo e pelo teor de água,. Além disso, pode-se observar que o modelo MVS7-RP, apesar de obter valor de id inferior (0,77), ainda classifica-se como “muito bom”, sendo uma boa opção para estimativa da RP em função de não necessitar realizar a separação

das frações silte e argila, facilitando e acelerando a obtenção de dados de entrada.

Na Tabela 29 são apresentados os coeficientes de correlação (r), determinação (R^2), índices de concordância (c) e desempenho (id), para os dados estimados de pressão de preconsolidação do solo (σ_p) utilizando máquinas de vetores de suporte (MVS) em treze arquiteturas desenvolvidas para dados gerais.

Tabela 29 - Valores do coeficiente de correlação (r), coeficiente de determinação (R^2), índice de concordância (c), índice de desempenho (id) e a classe de desempenho qualitativo dos diferentes modelos de MVS para estimativa da pressão de preconsolidação do solo (σ_p)

Modelo	c	r	R²	id	Classe
MVS1- σ_p	0,94	0,92	0,84	0,86	Ótimo
MVS2- σ_p	0,82	0,83	0,69	0,69	Bom
MVS3- σ_p	0,78	0,79	0,63	0,62	Regular
MVS4- σ_p	0,85	0,81	0,66	0,69	Bom
MVS5- σ_p	0,86	0,81	0,66	0,70	Bom
MVS6- σ_p	0,84	0,79	0,63	0,67	Bom
MVS7- σ_p	0,82	0,77	0,59	0,63	Regular
MVS8- σ_p	0,74	0,68	0,46	0,50	Fraco
MVS9- σ_p	0,85	0,80	0,64	0,68	Bom
MVS10- σ_p	0,73	0,65	0,42	0,47	Muito Fraco
MVS11- σ_p	0,72	0,71	0,51	0,51	Fraco
MVS12- σ_p	0,74	0,68	0,47	0,51	Fraco
MVS13- σ_p	0,55	0,48	0,23	0,26	Péssimo

Fonte: Autor

Assim como com as redes neurais artificiais (RNA), as máquinas de vetores de suporte também apresentaram boa capacidade preditiva para a pressão de preconsolidação do solo (σ_p), obtendo índices de desempenho superiores aos de estimativa de RP, entretanto para o modelo que utiliza todas as variáveis de entrada consideradas para este estudo.

O modelo MVS1- σ_p classificou-se como “ótimo” obtendo um índice de desempenho (id) igual a 0,86. Entretanto, o modelo MVS9- σ_p pode ser considerado uma boa opção para a estimativa da pressão de preconsolidação do solo (σ_p), visto que suas variáveis de entrada são apenas as frações granulométricas (areia, silte e argila) e a umidade volumétrica (θ), e seu desempenho classificou-se como “bom”, concordando com estudos de vários autores (AJAYI, 2010; BUSSCHER, 1990; DEBIASE, 2008; DIAS JUNIOR, 2004; GUBIANI, 2012; MOSADDEGHI, 2006;

RIBON; TAVARES FILHO, 2008) que apontam o teor de água no solo como variável de grande influência para a obtenção dos índices indicadores de capacidade de carga do solo.

4.4.4 Comparação das FTPs desenvolvidas pelos modelos

A Tabela 30 apresenta os coeficiente de correlação (r), de determinação (R^2), índices de concordância (c) (WILLMOTT et al., 1981) e desempenho (id) (Tabela 9) sugeridos por Camargo e Sentelhas (1997), para os dados estimados de resistência do solo à penetração (RP) utilizando regressão linear múltipla (RLM), redes neurais artificiais (RNA), máquinas de vetores de suporte (MVS) e o modelo não-linear de Busscher, desenvolvidos para dados gerais (dados de classes texturais e manejos diversos).

Tabela 30 - Valores do coeficiente de correlação (r), coeficiente de determinação (R^2), índice de concordância (c), índice de desempenho (id) e a classe de desempenho qualitativo dos diferentes modelos de estimativa da resistência do solo à penetração (RP)

Geral					
Modelo	c	r	R²	id	Classe
BUSSCHER	0,2619	0,1487	0,0221	0,0389	Péssimo
RLM5-RP	0,5983	0,3989	0,1591	0,2387	Péssimo
RNA5-RP	0,9147	0,8521	0,7261	0,7794	Muito Bom
MVS5-RP	0,9249	0,8672	0,7520	0,8021	Muito Bom
BUSSCHER	0,2224	0,1166	0,0136	0,0259	Péssimo
RLM6-RP	0,4209	0,1977	0,0391	0,0832	Péssimo
RNA6-RP	0,8935	0,8073	0,6517	0,7213	Bom
MVS6-RP	0,9296	0,8738	0,7635	0,8123	Muito Bom

Fonte: Autor

Observa-se que ao se utilizar todos os dados, de forma a não discriminar tipos de solo ou tipo de manejo o desempenho das redes neurais artificiais para a estimativa da resistência do solo à penetração foi melhor em RNA5-RP, classificando-se com “muito bom” assim como as máquinas de vetores de suporte, porém com o índice de desempenho (id) um pouco inferior (0,7794) ao da MVS5-RP que obteve “ id ” igual a 0,8021, sendo estes modelos muito superiores aos modelos RLM-5RP e ao modelo de Busscher, classificados como “péssimo” com índices de

desempenho de 0,2387 e 0,0389 respectivamente.

Considerando as mesmas condições do banco de dados anterior, o desempenho das máquinas de vetores de suporte (MVS) obteve o seu maior índice (0,8123) para os dados de entrada do modelo MVS6-RP (areia, silte, argila, densidade do solo e a umidade volumétrica), também com classificação “muito bom”, porém com uma variável de entrada a menos (densidade de partícula), sendo desta forma, o melhor modelo para a estimativa da resistência do solo à penetração para dados gerais.

A Tabela 31 apresenta os coeficiente de correlação (r), de determinação (R^2), índices de concordância (c) e desempenho (id), para os dados estimados de resistência do solo à penetração (RP), de maneira a comparar os modelos de regressão linear múltipla (RLM), redes neurais artificiais (RNA) e máquinas de vetores de suporte (MVS), todas contendo como variáveis de entrada a densidade do solo (D_s) e a umidade volumétrica (θ), ao modelo não-linear de Busscher que conta apenas com estas mesmas variáveis. Esta comparação foi realizada para dados gerais (dados de classes texturais e manejos diversos).

Tabela 31 - Valores do coeficiente de correlação (r), coeficiente de determinação (R^2), índice de concordância (c), índice de desempenho (id) e a classe de desempenho qualitativo dos diferentes modelos de estimativa da resistência do solo à penetração (RP) da arquitetura M13

Modelo	Geral				
	c	r	R^2	id	Classe
BUSSCHER	0,22	0,12	0,01	0,03	Péssimo
RLM13-RP	0,22	0,11	0,01	0,02	Péssimo
RNA13-RP	0,59	0,39	0,15	0,23	Péssimo
MVS13-RP	0,62	0,38	0,14	0,24	Péssimo

Fonte: Autor

Observou-se que nestas condições todos os métodos classificaram-se como “péssimo”, entretanto, pode-se constatar, ao observar os valores obtidos em seus índices de desempenho (id) e coeficientes de determinação (R^2), que capacidade preditiva das máquinas de vetores de suporte (MVS) seguida das redes neurais artificiais (RNA) é muito superior à regressão linear múltipla e ao método de Busscher, sendo este último amplamente utilizado por se ajustar bem a dados experimentais (GUBIANI, 2012).

Na Tabela 32 são apresentados os coeficiente de correlação (r), de determinação (R^2), índices de concordância (c) e desempenho (id), para os dados estimados de resistência do solo à penetração (RP), de maneira a comparar os modelos de regressão linear múltipla (RLM), redes neurais artificiais (RNA) e máquinas de vetores de suporte (MVS), todas contendo como variáveis de entrada a densidade do solo (D_s) e a umidade volumétrica (θ), ao modelo não-linear de Busscher. Esta comparação foi realizada para dados de um solo com classe textural distinta (franco arenoso de uma única área produtiva sujeito à diferentes manejos).

Tabela 32 - Valores do coeficiente de correlação (r), coeficiente de determinação (R^2), índice de concordância (c), índice de desempenho (id) e a classe de desempenho qualitativo dos diferentes modelos de estimativa da resistência do solo à penetração (RP) para solo franco arenoso (FA1)

Franco Arenoso – FA1					
Modelo	c	r	R²	id	Classe
BUSSCHER	0,64	0,49	0,24	0,31	Péssimo
RLM-FA1-RP	0,63	0,47	0,22	0,30	Péssimo
RNA-FA1-RP	0,61	0,52	0,27	0,32	Péssimo
MVS-FA1-RP	0,67	0,52	0,27	0,35	Péssimo

Fonte: Autor

Pode-se notar que nestas condições todos os métodos classificaram-se como “péssimo”, entretanto, diferente do ocorrido para dados gerais, os modelos observados obtiveram índices de desempenho (id) e coeficientes de determinação (R^2) com valores bem próximos, sendo a capacidade preditiva das máquinas de vetores de suporte (MVS) um pouco superior ($id=0,35$) aos demais e ao modelo destinado a dados gerais (MVS13-RP).

A Tabela 33 apresenta os coeficiente de correlação (r), de determinação (R^2), índices de concordância (c) e desempenho (id), para os dados estimados de resistência do solo à penetração (RP), de maneira a comparar os modelos de regressão linear múltipla (RLM), redes neurais artificiais (RNA) e máquinas de vetores de suporte (MVS) ao modelo não-linear de Busscher. A arquitetura de entrada dos modelos é semelhante ao modelo anterior (densidade do solo e umidade volumétrica), diferenciando-se em função dos dados de entrada serem de diferentes solos com a mesma classe textural (franco arenoso de diferentes localidades).

Tabela 33 - Valores do coeficiente de correlação (r), coeficiente de determinação (R^2), índice de concordância (c), índice de desempenho (id) e a classe de desempenho qualitativo dos diferentes modelos de estimativa da resistência do solo à penetração (RP) para solo franco arenoso (FA2)

Franco Arenoso – FA2					
Modelo	c	r	R^2	id	Classe
BUSSCHER	0,33	0,13	0,02	0,04	Péssimo
RLM-FA2-RP	0,32	0,11	0,01	0,04	Péssimo
RNA-FA2-RP	0,69	0,57	0,32	0,39	Péssimo
MVS-FA2-RP	0,68	0,47	0,22	0,32	Péssimo

Fonte: Autor

Nesta condição, apesar de todos os modelos se classificarem como “péssimo”, é notória a inferioridade da capacidade preditiva dos modelos de Busscher e de RLM, ambos com índice de desempenho de 0,04, sendo as redes neurais artificiais (RNA) o método de estimativa que alcança os melhores resultados (id=0,39) para solos de mesma classe textural sem que se leve em consideração a localidade da amostra.

Os modelos desenvolvidos para estimativa da resistência do solo à penetração com dados de solo do tipo Muito Argiloso, de uma mesma propriedade e exposto ao mesmo manejo, obtiveram os coeficiente de correlação (r), de determinação (R^2), índices de concordância (c) e desempenho (id) apresentados abaixo na Tabela 34, com a finalidade de compará-los entre si.

Tabela 34 - Valores do coeficiente de correlação (r), coeficiente de determinação (R^2), índice de concordância (c), índice de desempenho (id) e a classe de desempenho qualitativo dos diferentes modelos de estimativa da resistência do solo à penetração (RP) para solo muito argiloso (MA)

Muito Argiloso					
Modelo	c	r	R^2	id	Classe
BUSSCHER	0,86	0,79	0,62	0,68	Bom
RLM-MA-RP	0,85	0,78	0,61	0,67	Bom
RNA-MA -RP	0,88	0,80	0,65	0,71	Bom
MVS-MA -RP	0,86	0,80	0,63	0,69	Bom

Fonte: Autor

Observou-se que em condições singulares todos os métodos apresentaram índices de desempenho classificados como “bom”, destacando-se, assim como nas

arquitecturas anteriores os modelos gerados por inteligência artificial RNA e MVS com índices de desempenho de 0,71 e 0,69, respectivamente, entretanto não diferenciando-se estatisticamente do método de Busscher que obteve “id” igual a 0,68.

A Tabela 35 apresenta os coeficiente de correlação (r), de determinação (R^2), índices de concordância (c) (WILLMOTT et al., 1981) e desempenho (id) (Tabela 9) sugeridos por Camargo e Sentelhas (1997), para os dados estimados de pressão de preconsolidação do solo (σ_p) apenas dos modelos de regressão linear múltipla (RLM), redes neurais artificiais (RNA) e máquinas de vetores de suporte (MVS) desenvolvidos para dados gerais (dados de classes texturais e manejos diversos) que apresentaram os melhores desempenhos.

Tabela 35 - Valores do coeficiente de correlação (r), coeficiente de determinação (R^2), índice de concordância (c), índice de desempenho (id) e a classe de desempenho qualitativo dos diferentes modelos de estimativa da pressão de preconsolidação do solo (σ_p)

Geral					
Modelo	c	r	R²	id	Classe
RLM1- σ_p	0,7466	0,6550	0,4290	0,4890	Muito Fraco
RNA1- σ_p	0,9665	0,9407	0,8849	0,9092	Ótimo
MVS1- σ_p	0,9403	0,9188	0,8442	0,8640	Ótimo

Fonte: Autor

Nota-se que ao se utilizar todos os dados, de forma a não discriminar tipos de solo ou manejo agrícola o desempenho das redes neurais artificiais para a estimativa da pressão de preconsolidação do solo (σ_p) foi melhor em RNA1- σ_p , classificando-se com “ótimo” assim como as máquinas de vetores de suporte, porém com o índice de desempenho (id) um pouco superior (0,9092) ao da MVS1-RP que obteve “id” igual a 0,8640, sendo estes modelos muito superiores aos modelos RLM1- σ_p , classificado como “muito fraco” com índice de desempenho de 0,4890.

A Tabela 36 apresenta os coeficiente de correlação (r), de determinação (R^2), índices de concordância (c) e desempenho (id), para os dados estimados de pressão de preconsolidação do solo (σ_p), de maneira a comparar os modelos de regressão linear múltipla (RLM), redes neurais artificiais (RNA) e máquinas de vetores de suporte (MVS) ao método de Dias Junior e Pierce (1995). A arquitetura de entrada dos modelos é constituída apenas de densidade do solo (D_s) e umidade volumétrica (θ), sendo os dados de um solo do tipo Muito Argiloso.

Tabela 36 - Valores do coeficiente de correlação (r), coeficiente de determinação (R^2), índice de concordância (c), índice de desempenho (id) e a classe de desempenho qualitativo dos diferentes modelos de estimativa da pressão de preconsolidação do solo (σ_p) vs o método de Dias Junior e Pierce (1995) para solo muito argiloso (MA)

Muito Argilosa					
Modelo	c	r	R²	id	Classe
RLM13- σ_p x DIAS JR & PIERCE	0,33	0,99	0,98	0,32	Péssimo
RNA13- σ_p x DIAS JR & PIERCE	0,97	0,95	0,90	0,92	Ótimo
MVS13- σ_p x DIAS JR & PIERCE	0,99	0,99	0,99	0,98	Ótimo

Fonte: Autor

Observou-se que os modelos utilizados para comparação (RLM13- σ_p , RNA13- σ_p e MVS13- σ_p) são classificados como “péssimo” para dados gerais, entretanto, comparando-se ao método de Dias Junior e Pierce as FTPs geradas por inteligência artificial (RNA e MVS) apresentaram índices de desempenho classificados como “ótimo”, sendo o oposto do método de RLM, que obteve índice de desempenho 0,32, classificado como “péssimo”.

5 CONCLUSÃO

De acordo com a metodologia utilizada e as condições de realização deste estudo pode-se concluir que:

- As redes neurais artificiais apresentaram capacidade preditiva superior aos demais modelos para estimativa da resistência do solo à penetração para dados de solos de mesma classe textural e mesmo manejo agrícola;
- As redes neurais artificiais apresentaram desempenho superior para estimativa da pressão de preconsolidação do solo para dados de solos considerados gerais;
- As máquinas de vetores de suporte apresentaram capacidade preditiva superior aos demais modelos para resistência do solo à penetração para dados gerais de solos;
- O modelo MVS constituído com variáveis de entrada areia, silte, argila, densidade do solo e a umidade volumétrica foi o que apresentou maior capacidade preditiva para a resistência do solo à penetração para dados de solos gerais;
- As MVS apresentaram alto desempenho, sendo superior aos demais modelos de estimativa da pressão de preconsolidação do solo quando comparados ao método Dias Junior e Pierce (1995);
- O modelo MVS de maior capacidade preditiva quando comparado ao método Dias Junior e Pierce (1995) foi o constituído com densidade do solo e a umidade volumétrica;
- Para a estimativa de resistência do solo à penetração os modelos baseados em inteligência artificial (RNA e MVS) apresentaram índice de desempenho superior ao modelo não-linear de Busscher em todos os cenários estudados.

REFERÊNCIAS

- AJAYI, A. E.; DIAS JUNIOR, M. S.; CURI, N.; ARAUJO JUNIOR, C. F.; ALADENOLA, O. O.; SOUZA, T. T. T.; INDA JUNIOR, A. V. Comparison of estimation methods of soil strength in five soils. **Revista Brasileira de Ciência do Solo**, Viçosa, v.33, n.3, p.487-495, 2009.
- AJAYI, A. E.; DIAS JUNIOR, M. S.; CURI, N.; OKUNOLA, A.; SOUZA, T. T. T.; SILVA PIRES, B. Assessment of vulnerability of Oxisols to compaction in the Cerrado region of Brazil. **Pedosphere**, Nanjing, v. 20, n. 2, p. 252-260, 2010.
- ALEXANDROU, A.; EARL, R. The relationship among the precompaction stress, volumetric water content and initial dry bulk density of soil. **Journal of Agricultural Engenniring. Research**. v 71, p. 75–80. 1998.
- AMORIM, M. J. V.; BARONE, D.; MANSUR, A. U. Técnicas de Aprendizado de Máquina Aplicadas na Previsão de Evasão Acadêmica. In: XIX Simpósio Brasileiro de Informática na Educação (SBIE) 2008.
- ANDRADE. M. C. de; NETO, A. R.; ROSA, R. R.; SAWANT, H. S.; FERNANDES, F. C. R. Spatiotemporal Patterns Estimation Using a Multilayer Perceptron Neural Network in a Solar Physics Application. Learning and Nonlinear Models. **Revista da Sociedade Brasileira de Redes Neurais**, v.1, n.2, p. 159-167, 2003.
- Angelotti Netto, A. **Estimativa da retenção de água no solo a partir do uso de equipamentos não convencionais, redes neurais artificiais e funções de pedotransferência**. 2007. 167p. Tese (Doutorado em em Ciências da Engenharia Ambiental), - Universidade de São Paulo. São Carlos, 2007.
- ARAÚJO, R.; GOEDERT, W. J.; LACERDA, M. P. C. Qualidade de um solo sob diferentes usos e sob cerrado nativo. **Revista Brasileira de Ciência do Solo**, Viçosa, v.31, n.5 p. 1099-1108, 2007.
- ARVIDSSON, J. Subsoil compaction caused by heavy sugarbeet harvesters in southern Sweden. Soil physical properties and crop yield in six field experiments. **Soil and Tillage Research**, Amsterdam, v. 60, n.1-2, p. 67-78, June 2001.
- ASSOULINE, S. Modeling soil compaction under uniaxial compression. **Soil Science Society of America Journal**, Madson, v. 66, n. 6, p.1784-1787, 2002.
- BALESTRASSI, P. P. **Identificação de Padrões em Gráficos de Controle Estatístico de Processos, em tempo real, Utilizando Séries Temporais e Redes Neurais Artificiais**. 2000. 217p. Tese (Doutorado em Engenharia de Produção) - Universidade Federal de Santa Catarina, Florianópolis, 2000.
- BARANAUSKAS, J. A.; MONARD, M. C.. Reviewing some machine learning concepts and methods. Technical Report 102, Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo, São Carlos. 2000. Disponível em: <ftp://ftp.icmc.usp.br/pub/BIBLIOTECA/rel_tec/RT_102.ps.zip>. Acesso em: 26 mai. 2014.

BARTHELEMY, J. F. M.; HAFTKA, R. Approximation Concepts for Optimal Structural Design – A Review. **Structural Optimization**, v. 5, p. 129-144. 1993.

BEALE, R.; JACKSON, T. Neural Computing: An Introduction. **Institute of Physics Publishing**. 240 pp, 1994.

BEUTLER, A.N.; CENTURION, J.F.; SILVA, A.P.; BARBOSA, J.C. Intervalo hídrico ótimo e produtividade de cultivares de soja. **Revista Brasileira de Engenharia Agrícola e Ambiental**, Campina Grande, v.10, n.3, p.639-645, 2006.

BEUTLER, N. A.; CENTURION, J. F.; SILVA, A. P. Comparação de penetrômetros na avaliação da compactação de Latossolos. **Revista Engenharia Agrícola**, Jaboticabal, v. 27, p. 146-151, 2007.

BLAINSKI, E.; TORMENA, C.A.; FIDALSKI, J. & GUIMARÃES, R.M.L. Quantificação da degradação física do solo por meio da curva de resistência do solo à penetração. **Revista Brasileira de Ciência do Solo**, Viçosa, v. 32, p. 975-983, 2008.

BOCANEGRA, C. W. R. **Procedimentos para tornar mais Efetivo o uso das Redes Neurais Artificiais em Planejamento de Transporte**. 2002. 93p. Dissertação (Mestrado em Engenharia Civil) – Universidade de São Paulo, São Carlos, 2002.

BOSER, B.E.; GUYON, I.; VAPNIK, V.N. A training algorithm for optimal margin classifiers. In Proceedings of the Fifth Annual Workshop of Computational Learning Theory, 5, 144-152, Pittsburgh, ACM. 1992.

BOUMA, J. Using soil survey data for quantitative land evaluation. **Soil Science Society of America Proceedings**, Madison, v. 9, p. 177-213, 1989.

BOUMA, J.; LANEN, H. A. J. Transfer functions and threshold values: from soil characteristics to land qualities. In: Beek, K., P.A. Barrough and D. D McCormack (Editors). Proc. WORKSHOP BY ISSS/SSSA ON QUANTIFIED LAND EVALUATION PROCEDURES, ITC publication. 6., Enschede. **Proceedings**...Netherlands, 1987. p.106-111.

BRAGA, A. P.; CARVALHO; A. P. L. F.; LUDEMIR; T. B. **Redes neurais artificiais: Teoria e aplicações**. Rio de Janeiro: Livros Técnicos e Científicos, 2000. 262 p.

BRAGA, F.V.A. **Estimativa dos parâmetros da resistência do solo ao cisalhamento através de Pedotransferência**. 2014. 98 f. Tese (Doutorado em Engenharia Agrícola) – Universidade Federal de Santa Maria, Santa Maria, 2014.

BRITO FILHO, F. J. B. **Previsão de vazões com máquina de vetor de suporte**. 2012. 61p. Trabalho de Conclusão de Curso (Graduação em Engenharia da Computação) – Universidade de Pernambuco, Recife, 2012.

BUDIMAN, M.; McBRATNEY, A.B.; MENDONÇA-SANTOS, M.L. & SANTOS, H.G. Revisão sobre funções de pedotransferência (PTFs) e novos métodos de predição de classes e atributos do solo. Rio de Janeiro, **Embrapa Solos - Documentos**, n. 45, 2003. 50p.

BUSSCHER, W. J. Adjustment of flat-tipped penetrometer resistance data to a common water content. **Transactions of the ASAE**, Michigan, v. 33, n. 2, p. 519-524, Mar./Apr., 1990.

CANARACHE, A. PENETR - a generalized semi-empirical model estimating soil resistance to penetration. **Soil Tillage Research**, Amsterdam, v.16, n.1, p.51-70, 1990.

CANARACHE, A.; HORN, R. & COLIBAS, I. Compressibility of soils in a long term field experiment with intensive deep ripping in Romania. **Soil Tillage Research.**, v.56, p.185-196, 2000.

CANILLAS, E. C.; SALOKHE, V. M. A decision support system for compaction assessment in agricultural soils. **Soil and Tillage Research**, Amsterdam, v. 65, n. 2, p. 221-230, 2002.

CARVALHO, L. A.; NETO, V. J, M.; SILVA, L. F.; PEREIRA, J. G.; NUNES, W. A. G. A.; CHAVES, C. H. C. Resistência mecânica do solo à penetração (RMP) sob cultivo de cana-de-açúcar, no município de Rio Brilhante-MS. **Agrarian**, v.1, n.2, p.7-22, 2008.

CASAGRANDE, A. The determination of the pre-consolidation load and its practical significance. In: INTERNATIONAL CONFERENCE ON SOIL MECHANICS AND FOUNDATION ENGINEERING, 3., 1936, Cambridge. **Proceedings...**Cambridge: Harvard University, 1936. p. 60-64.

CHONG, IL-GYO, JUN, CHI-HYUCK. Performance of some variable selection methods when multicollinearity is present. **Chemometrics and Intelligent Laboratory Systems**, v. 78 p. 103, 2005.

COGDILL, R.; DARDENNE, P.; **Journal Near Infrared Spectroscopy**, v.12, p 93, 2004.

COLLARES, G.C., REINERT, D.J. & REICHERT, J.M. Desenvolvimento e funcionalidade de um penetrômetro de cone com taxa constante de penetração no solo. In: REUNIÃO BRASILEIRA DE MANEJO E CONSERVAÇÃO DO SOLO E DA ÁGUA, 15., Santa Maria, 2004. **Anais**. Santa Maria, Universidade Federal de Santa Maria, 2004. CD-ROM

CORTES, C.; VAPNIK, V. Support Vector Networks. Machine Learning. Kluwer **Academic Publishers**. 20(3), p. 273-297. 1995.

CORTEZ, P. Data Mining with Neural Networks and Support Vector Machines using the R/rminer Tool, In: P. Perner (Ed.), Advances in Data Mining. **Proceedings of 10th Industrial Conference on Data Mining**, lecture notes in artificial intelligence 6171. p. 572-583. Berlin: Springer. 2010.

CRISITIANINI, N. E.; SHAWE-TAYLOR, J. **An introduction to support vector machines**. Cambridge University Press, 2000.

CUNHA, J.P.A.R. da; VIEIRA, L.B.; MAGALHÃES, A.C. Resistência mecânica do solo à penetração sob diferentes densidades e teores de água. **Engenharia na Agricultura, Viçosa**, v.10, n.1-4, p.1-7, 2002.

DAWIDOWSKI, J.B.; MORRISON, J.E. & SNIEG, M. Measurement of soil layer strength with plate sinkage and uniaxial confined methods. *Trans. Am. Soc. Eng.*, 4:1059-1064, 2001.

DAUDA, A.; SAMARI, A. Cowpea yield response to soil compaction under tractor on a sandy loam soil in the semi-arid region of northern Nigeria. **Soil and Tillage Research**, Amsterdam, v. 68, n. 1, p. 17-22, Oct. 2002.

DEFOSSEZ, P.; RICHARD, G. Models of soil compaction due to traffic and their evaluation. **Soil and Tillage Research**, Amsterdam, v. 67, n. 1, p. 41-64. 2002.

DEPARTMENT OF THE ARMY. U. S. Army Corps of Engineers. Engineer Manual - EM 1110-2-1906. Washington, D. C. 20314-1000, 1970.

DIAS JUNIOR, M. S.; PIERCE, F. J. A simple procedure for estimating preconsolidation pressure from soil compression curves. *Soil Technology*, v. 8, n.2, p. 139-151, nov. 1995.

DIAS JUNIOR, M. S.; PIERCE, F. J. Revisão de literatura: O processo de compactação do solo e sua modelagem. **Revista Brasileira de Ciência do Solo**, Viçosa, v.20, p.175-182, 1996.

DIAS JÚNIOR, M.S.; SILVA, A.R.; FONSECA, S.; LEITE, F.P. Método alternativo de avaliação da pressão de preconsolidação por meio de um penetrômetro. **Revista Brasileira de Ciência do Solo**. Viçosa, v. 28, p. 805-810. 2004.

DIAS JUNIOR, M. S.; FONSECA, S.; ARAÚJO JUNIOR, C. F.; SILVA, A. R. Soil compaction due to forest harvest operations. **Pesquisa Agropecuária Brasileira**, Brasília, v. 42, n. 2, p. 257-264, 2007.

DIAS JUNIOR, M. S.; SILVA, S. R.; SANTOS, N. S.; ARAUJO JUNIOR, C. F. Assessment of the soil compaction of two ultisols caused by logging operations. **Revista Brasileira de Ciência do Solo**, Viçosa, v. 32, n. 6, p. 2245-2253, Nov./Dec. 2008.

DINIZ, L.S. **Regionalização de parâmetros de modelo chuva-vazão usando redes neurais**. 2008. 197 f. Tese (Doutorado em Engenharia de Recursos Hídricos e Saneamento Ambiental) – Universidade Federal do Rio Grande do Sul, Porto Alegre, 2008.

DÜRR, C.; AUBERTOT, J. N. Emergence of seedling of sugar beet (*Beta vulgaris*L.) as affected by aggregate size, roughness and position of aggregates in the seedbed. **Plant and Soil**, Amsterdam, v. 219, n. 1-2, p. 211-220, 2000.

EARL, R. Assessment of the behaviour of field soils during compaction. **Journal of Agricultural Engineering Research**. v. 68, p. 147–157. 1997.

EBERHART, R.; DOBBINS, R. **Neural Networks PC Tools - A Practical Guide**. Academic Press, San Diego, 1990.

FABRI, J. A., Redes Neurais Artificiais. [S.l.] 1999. Disponível em: <<http://users.femanet.com.br/~fabri/RNAs.htm>> . Acesso em: 03 out. 2014.

FERRAZ, R. C. **Sistema web e mobile para estimativa de evapotranspiração utilizando redes neurais artificiais**. 2013. 119f. Tese (Doutorado em Engenharia Agrícola) – Universidade Federal de Santa Maria, Santa Maria, 2013.

FERREIRA, M. M. Caracterização física do solo. In: van LIER, Q. J. **Física do solo**. 1. Ed. Viçosa: Sociedade Brasileira de Ciência do Solo, 2010. Cap. 1, p. 1 - 27.

FREUND, Y.;SCHAPIRE, R. E. A decision-theoretic generalization of on-line learning and an application to boosting. **J. Comput. Syst. Sci.** 1997. pp. vol. 55, no. 1,119–139.

FREDDI, O. S. **Avaliação do intervalo hídrico ótimo em latossolo vermelho cultivado com milho**. . 2007. 105 f. Tese (Doutorado em Agronomia) – Universidade Estadual Paulista “Julio De Mesquita Filho”, Jaboticabal, 2007.

FRITTON, D. D. An improved empirical equation for uniaxial soil compression for a wide range of applied stresses. **Soil Science Society of America Journal**, Madson, v.65, p.678-684, 2001.

FLORES, J. P. C.; ANGHINONI, I.; CASSOL, L. C.; CARVALHO, P. C. F.; LEITE, J. G. D. B.; FRAGA T. I. Atributos físicos do solo e rendimento de soja em sistema plantio direto em integração lavourapeçuária com diferentes pressões de pastejo. **Revista Brasileira de. Ciência do Solo**, Viçosa, v. 31, p. 771-780, 2007.

FONTANELA, E. **Parâmetros físico-hídricos de um latossolo sob diferentes sistemas de manejo e níveis de tráfego**. 2008. Dissertação. 78f. (Mestrado em Ciência do Solo), - Universidade Federal de Santa Maria, Santa Maria, 2008.

FONTANELA, E. **Preparos e propriedades físicas de um solo arenoso para cana-de-açúcar e mandioca no rio grande do sul**. 2012. Tese. 159p. (Doutorado em Ciência do Solo), - Universidade Federal de Santa Maria, Santa Maria, 2012.

GALVÃO, C.O.; VALENÇA, M.J.S. (org.) **Sistemas inteligentes: aplicações a recursos hídricos a ciências ambientais**. Porto Alegre: Editora da Universidade, UFRGS, ABRH, 1999. 246 p.

GENRO JUNIOR, S. A.; REINERT, D. J.; REICHERT J. M. Variabilidade temporal da resistência à penetração de um latossolo argiloso sob semeadura direta com rotação de culturas. **Revista Brasileira de. Ciência do Solo**, Viçosa, v. 28, p. 477-484, 2004.

GONTIJO, I.; DIAS JÚNIOR, M.S.; OLIVEIRA, M.S.; ARAUJO JUNIOR, C. F.; PIRES, B. S.; OLIVEIRA, C. A. Planejamento amostral da pressão de preconsolidação de um latossolo vermelho distroférico. **Revista Brasileira de Ciência do Solo**. Viçosa, v. 31, n. 6, p. 1245-1254. 2007.

GREGORY, A. S.; WHALLEYA, W. R.; WATTS, C. W.; BIRDA, N.R.A; HALLETTB, P.D.; WHITMORE, A.P. Calculation of the compression index and precompression stress from soil compression test data. **Soil and Tillage Research**, v. 89, n. 1, p. 45-57, 2006.

GUBIANI, P. I. **Regularidade de resposta da cultura do milho à compactação do solo**. 2012. Tese. 152f. (Doutorado em Ciência do Solo) - Universidade Federal de Santa Maria, Santa Maria, 2012.

GUBIANI, P. I.; REICHERT, J. M.; REINERT, D. J. Interação entre disponibilidade de água e compactação do solo no crescimento e na produção de feijoeiro. **Revista Brasileira de Ciência do Solo**. Viçosa, v. 38, P. 765-773. 2014.

GUIMARÃES, A. M. Aplicação de computação evolucionária na mineração de dados físico-químicos da água e do solo, 2005. Tese. 127p. (Doutorado em Agronomia – Energia na Agricultura), - Universidade Estadual Paulista, Botucatu, 2005.

GUIMARÃES, A. M.; VRIESMANN, L. M.; TOMASI, A. L. B.; CANTERI, M. G.; MATHIAS, I. M. Aplicação de Técnicas de Data Mining na obtenção de padrões de características físico-químicas do solo em função de sua produtividade. In: X Encontro Anual de Iniciação Científica e I Encontro de Pesquisa da UEPG, Anais..., Ponta Grossa: Editora UEPG, v.1. p.292 – 293, 2001.

GUNN, S. R.. Support Vector Machines for Classification and Regression. 1998.

GUPTA, S.C.; ALLMARAS, R.R. Models to assess the susceptibility of soils to excessive compaction. **Advances in Soil Science**, London, v.6, p.65-100, 1987.

GYSI, M. Compaction of a eutric cambisol under heavy wheel traffic in Switzerland: field data and a critical state soil mechanics model approach. **Soil and Tillage Research**, Amsterdam, v. 61, n. 3/4, p. 133-142, Sept. 2001.

HAIR JUNIOR, J. F.; ANDERSON, R. E.; TATHAM, R. L.; BLACK, W. C. Análise multivariada de dados. 5. ed. Porto Alegre: Bookman, 2005.

HÅKANSSON, I. **Machinery-induced compaction of arable soils: incidence, consequences, counter-measures**. 2005. 153p. Uppsala, Sweden, Department of Soil Sciences, Division of Soil Management, 2005.

HÅKANSSON, I.; MEDVEDEV, V. W. Protection of soils from mechanical overloading by establishing limits for stresses caused by heavy vehicles. **Soil and Tillage Research**, v.35, p. 85-97, 1995.

HAYKIN, S. Neural networks. Englewood Cliffs, NJ: Prentice-Hall; 1999.

HAYKIN, S. Redes Neurais: Princípios e prática. 2.ed. Porto Alegre: Bookman, 2001. 900p.

HEARST, M. A. Support vector machines. **IEEE Intelligent Systems**. p. 18–28. 1998.

HILLEL, D. **Introduction to soil physics**. San Diego: Academic, 1982. 364 p.

HOPFIELD, J. J. Neural Networks and Physical Systems with Emergent Computational Abilities. In: **Proceedings of the National Academy of Sciences**, v.79, Washington, USA. p.2554-2558, April 1982.

HOLTZ, R. D.; KOVACS, W. D. **An introduction to geotechnical engineering**. New Jersey, Prentice-Hall, Englewood Cliffs, 1981. 733 p.

HORN, R.; DOMZAL, H.; OUWERKERK, C. V. Soil compaction processes and their effects on the structure of arable soils and the environment. *Soil and Tillage Research*, v 35, p. 23-36, 1995.

HORN, R.; LEBERT, M. Soil compactability and compressibility. In: SOANE, B. D.; OUWERKERK, C. van. **Soil compaction in crop production**. Amsterdam: Elsevier, 1994. p.45-69.

HORN, R.; FLEIGE, H. A method for assessing the impact of load on mechanical stability and on physical properties of soils. **Soil Tillage Research**. v.73, p.89–99, 2003.

HORN, R. Compressibility of arable land. **Catena**, Jerusalém, v.11, p.53-71, 1988

IJIMA, M.; KNO, Y. Interspecific differences of the root system structures of four cereal species as affected by soil compaction. **Japanese Journal of Crop Science**, v.60, p.130-138, 1991.

IMHOFF, S. et al. Quantificação de pressões críticas para o crescimento de plantas. **Revista Brasileira de Ciência do Solo**, Viçosa, v. 25, p. 11-18, 2001.

IMHOFF, S.; DA SILVA, A.P.; FALLOW, D. Susceptibility to compaction, load support capacity, and soil compressibility of Hapludox. **Soil Science Society of America Journal**. Madison, v. 68, p. 17–24. 2004.

JULIÃO, L. G. F. **Compressibilidade de três latossolos em função da umidade e uso**. 2009. Dissertação. 41p. (Mestrado em Ciência do Solo) - Universidade Federal de Lavras, Lavras, 2009.

KAISER, D. R. **Estrutura e água em argissolo sob distintos preparos na cultura do milho**. 2010. Tese. 150f. (Doutorado em Ciência do Solo) - Universidade Federal de Santa Maria, Santa Maria, 2010.

KELLER T, ARVIDSSON J, DAWIDOWSKI JB, KOOLEN AJ. Soil precompression stress II. A comparison of different compaction tests and stress– displacement behaviour of the soil during wheeling. **Soil & Tillage Research**, v. 77, p. 97-108, 2004.

KERN, J. S. Evaluation of soil water retention models based on basic soil physical properties. **Soil Science Society of America Journal**, Madison, v. 59: p. 1134-1141, 1995.

KLEIN, V.A.; CAMARA, R.K. Rendimento da soja e intervalo hídrico ótimo em Latossolo Vermelho sob plantio direto escarificado. **Revista Brasileira de Ciência do Solo**, Viçosa, v. 31, p. 221-227, 2007.

KONDO, M. K.; DIAS JUNIOR, M. S. Compressibilidade de três latossolos em função da umidade e uso. **Revista Brasileira de Ciência do Solo**, Viçosa, v. 23, p. 211-218, 1999.

KONDO, M. K.; DIAS JUNIOR, M. S. Efeito do manejo e da umidade no comportamento compressivo de três latossolos. **Revista Brasileira de Ciência do Solo**, Viçosa, v. 23, p. 497-506, 1999.

KOVÁCS, Z. L. **Redes neurais artificiais: Fundamentos e aplicações**. 3.ed. São Paulo: Livraria da Física, 2002. 174p.

KUHN, M. The Karush-Kuhn-Tucker Theorem. **CDSEM Uni Mannheim**. 2006.

LANÇAS, K.P. Diagnóstico e controle localizado da compactação do solo. In: CONGRESSO INTERNACIONAL DO AGRONEGÓCIO DO ALGODÃO, SEMINÁRIO ESTADUAL DA CULTURA DO ALGODÃO, 5. Cuiabá, Anais...Cuiabá: Fundação de Apoio à pesquisa Agropecuário de Mato Grosso, p. 25-30, 2000.

LETEY, J. Relationship between soil physical properties and crop production. **Advances in Soil Science**, v.1, p.277-294, 1985.

LIMA, C.L.R. **Compressibilidade de solos versus intensidade de tráfego em um pomar de laranja e pisoteio animal em pastagem irrigada**. 2004. 60 p. Tese (Doutorado em Agronomia) - Universidade de São Paulo, Piracicaba, 2004.

LIMA, C.L.R.; SILVA, A.P.; IMHOFF, S.; LEÃO, T.P. Estimativa da capacidade de suporte de carga do solo a partir da avaliação da resistência à penetração. **Revista Brasileira de Ciência do Solo** Viçosa, v. 30 p.217–223, 2006.

LIMA, C.L.R.; REICHERT, J.M.; REINERT, D.J.; SUZUKI, L.E.A.S.; DALBIANCO, L. Densidade crítica ao crescimento de plantas considerando água disponível e resistência à penetração de um Argissolo Vermelho distrófico arênico. **Revista Ciência Rural**, Santa Maria, v. 37 p. 1166-1169, 2007.

LIMA, H. V.; SILVA, A. P.; JACOMINE, P. T. K.; ROMERO, R. E.; LIBARDI, P. L. Identificação e caracterização de solos coesos no estado do ceará. **Revista Brasileira de Ciência do Solo**, Viçosa, v. 28, p. 467-476, 2004.

LIMA, H. V.; SILVA, A. P.; ROMERO, R. E.; JACOMINE, P. T. K. Comportamento físico de um argissolo acinzentado coeso no estado do ceará . **Revista Brasileira de Ciência do Solo**, Viçosa, v. 29, p. 33-40, 2005.

LIMA, R. P.; DE LEÓN, M. J.; SILVA, A. R. Compactação do solo de diferentes classes texturais em áreas de produção de cana-de-açúcar. **Revista Ceres**, Viçosa, v. 60, n.1, p. 016-020, jan/fev, 2013.

LOPES, S.E.; FERNANDES, H.C.; VIEIRA, L.B.; MACHADO, C.C.; RINALDI, P.C.N. Compactação de um solo de uso florestal submetido ao tráfego de arraste de madeira. **Revista Árvore**, v.30, p.369-376, 2006.

LORENA, A. C.; CARVALHO, A. C. Uma Introdução às Support Vector Machines. **Revista de Informática Teórica e Aplicada**, v. 14, n. 2, p. 43-67, 2007.

MAIMON, O.; LIOR, R. **Data Mining and Knowledge Discovery Handbook**. 2. Ed. New York: Springer, 2010. 1285p.

MARASCA, I. **Atributos físicos do solo em áreas de plantio direto com e sem escarificação**. 2010. 61 f. Dissertação (Mestrado em Agronomia) - Universidade Estadual Paulista "Júlio de Mesquita Filho", Botucatu, 2010.

MARCOLIN, C. D. **Propriedades físicas de nitossolo e latossolos argilosos sob plantio direto**. 2006. 110 f. Dissertação (Mestrado em Agronomia) - Universidade de Passo Fundo, Passo Fundo, 2006.

MARTINS, S. G.; SILVA, M. L. N.; CURI, N.; FERREIRA, M. M. Avaliação de atributos físicos de um latossolo vermelho distroférico sob diferentes povoamentos florestais. **Cerne**, v. 8, n. 1, p. 032-041, 2002.

MARTINS, F. F.; MIRANDA, T. F. S. Avaliação da estabilidade de taludes. Desempenho das redes Neurais versus máquinas de vetores de suporte. **Repositorium**. Univerisdade do Minho. 2012 Disponível em: <<http://hdl.handle.net/1822/21450>> Acesso em: 14 mai. 2013.

MARTINS, P. C. C. **Capacidade de suporte de carga de diferentes classes de solos submetidas a diferentes usos**. 2012. Tese. 41p. (Doutorado em Ciência do Solo) - Universidade Federal de Lavras, Lavras, 2012.

MASLE, J.; FARQUHAR, G.D. Effects of soil strength on the relation of wateruse-efficiency and growth to carbon isotope discrimination in wheat seedlings. **Plant Physiology**, v.86, p.32-38, 1988.

MASLE, J.; PASSIOURA, J.B. The effect of soil strength on the growth of young wheat plants. **Australian Journal of Plant Physiology**, v.14, p.643-656, 1987.

MAVROFORAKIS, M. E.; THEODORIDIS, S. A Geometric Approach to Support Vector Machine (SVM) Classification. **IEEE Transactions on Neural Networks** , v. 17, n. 3, p. 672, mai., 2006. Disponível em: <<https://pdfs.semanticscholar.org/388b/29662423f0f5ef5a9046c5ca467a26ab64a0.pdf>>. Acesso em: 16 mai. 2014.

MAZURANA, M. Atributos físicos, mineralógicos e matéria orgânica de Solos relacionados à capacidade de suporte de carga. 2011. 169 f. Dissertação (Mestrado em Ciência do Solo) – Universidade Federal do Rio Grande do Sul, Porto Alegre, 2011.

McBRATNEY, A. B. et al. From pedotranfer functions to soil inference systems. **Geoderma**, Amsterdam, v.109, p.41-73, 2002.

McBRIDE, R. A.; JOOSSE, P. J. Overconsolidation in agricultural soils: pedotransfer functions for estimating preconsolidation stress. **Soil Science Society of America Journal**, Madison, v. 60, n. 2, p. 373-380, 1996.

McBRIDE, R.A.; WATSON, G.C. An investigation of reexpansion of unsaturated, structured soils during cycles static loading. **Soil and Tillage Research**, Amsterdam, v.17, n.3/4, p.241-253, 1990.

McCULLOCH, W. S. & PITTS, W. A Logical Calculus of the Ideas Imminent in Nervous Activity. **Bulletin of Mathematical Biophysics**, 5, p.115-133, 1943.

MEDEIROS, L. F. de. Redes neurais em delphi. Florianópolis: Visual Books Editora, 2003, 115p

MENDOZA, L. A. F. **Redes Neurais e Máquinas de Vetores de Suporte no reconhecimento de locutor usando coeficientes MFC e características do sinal global**. 2009. 129 f. Dissertação (Mestrado em Engenharia de Telecomunicações) – Universidade Federal Fluminense, Niterói, 2009.

MENTGES, M. I. **Implicações do uso do solo nas propriedades físico-hídricas e mecânicas de um argissolo vermelho-amarelo e de um gleissolo háplico**. 2010. Dissertação. 107 f. (Mestrado em Ciência do Solo), - Universidade Federal de Santa Maria, Santa Maria, 2010.

MENTGES, M.I.; REICHERT, J.M.; GUBIANI, P. I.; REINERT, D. J.; XAVIER, A. Alterações estruturais e mecânicas de solo de várzea cultivado com arroz irrigado por inundação. **Revista Brasileira de Ciência do Solo**, Viçosa, v. 37, p. 221-231, 2013.

MEROTTO, A.; MUNDSTOCK, C.M. Wheat root growth as affected by soil strength. **Revista Brasileira de Ciência do Solo**, Viçosa, v.23, p.197-202, 1999.

MENG, T.P. et al. Models to predict water retention in semiarid sandy soils. **Soil Science Society of America Journal**, Madison, v. 51, p. 1563- 565, 1987.

MINASNY, B.; Mc BRATNEY, A. B.; SANTOS, M. L.; SANTOS, H. G.. Revisão sobre funções de pedotransferência (PTFs) e novos métodos de predição de classes e atributos do solo. Rio de Janeiro: **Embrapa Solos** - Documentos, n. 45. 2003, 50p.

MINOUX, M. **Mathematical programming: Theory and algorithms**. Chichester W. Sussex and New York: Wiley, 1986.

MITCHELL, T. Machine Learning. [S.l.]: McGraw Hill, 1997. 414 p.

MOLIN, J. P.; DIAS, C. T. S.; CARBONERA, L. Estudos com penetrometria: Novos equipamentos e amostragem correta. **Revista Brasileira de Engenharia Agrícola e Ambiental**, Campina Grande, v. 16, n. 5, p. 584-590, 2012.

MOSADDEGHI, M.R.; HEMMAT, A.; HAJABBASI, M.A.; ALEXANDROU, A. Pre-compression stress and its relation with the physical and mechanical properties of a structurally unstable soil in Central Iran. **Soil Tillage Research**, v.70 p.53-64, 2003.

MOSADDEGHI, M.R.; KOOLEN, A.J.; HEMMAT, A.; HAJABBASI, M.A.; LERINK, P. Comparisons of different procedures of pre-compaction stress determination on weakly structured soils. **Journal of Terramechanics**, v.44 p.53-63, 2007.

MOUAZEN, A. M. et al. Two-dimensional prediction of spatial variation in topsoil compaction of a sandy loam field-based on measured horizontal force of compaction sensor, cutting depth and moisture content. **Soil and Tillage Research**, v. 74, p. 91-102, 2003.

MULLER, M; FILL, H. D. Redes Neurais aplicadas na propagação de vazões. In: SIMPOSIO BRASILEIRO DE RECURSOS HÍDRICOS, 15. Curitiba. Anais. Curitiba: ABRH, 2003.

NAGAOKA, M. E. **Uma abordagem baseada em redes neurais artificiais para a estimação de densidade de solo**. 2003. 144 f. Tese (Doutorado em Agronomia) - Universidade Estadual Paulista "Júlio de Mesquita Filho", Botucatu, 2003.

NAGAOKA, M. E. et al. Um método para estimar densidade de solo utilizando redes neurais artificiais. **Energia na Agricultura**, vol. 20, p.53-68, 2005

NUNES, P.G.A. **Uma nova técnica para seleção de variáveis em calibração multivariada aplicada às espectrometrias uv-vis e nir**. 2008. 121 f. Tese (Doutorado em Química) – Universidade Federal da Paraíba, João Pessoa, 2008.

OLIVEIRA, L. B. RIBEIRO, M. R.; JACOMINE, P. K. T.; RODRIGUES, J. J. V.; MARQUES, F. A. Funções de pedotransferência para predição da umidade retida a potenciais específicos em solos do Estado de Pernambuco. **Revista Brasileira de Ciência do Solo**, Viçosa, v. 26, n. 26, p. 315-323, jan. 2002.

OLIVEIRA, A. R. **Redes neurais artificiais aplicadas na detecção, classificação e localização de defeitos em linhas de transmissão**. 2005. 132p. Dissertação (Mestrado em Engenharia Elétrica), - Universidade Federal de Juiz de Fora. Juiz de Fora, 2005.

OLIVEIRA, V. S.; ROLIM, M. M.; COSTA, Y. D. J.; PEDROSA, E. M. R.; SILVA, E. F. F. Compressibilidade de um Argissolo Amarelo distrocoeso submetido a diferentes manejos. **Revista Brasileira de Engenharia Agrícola e Ambiental**, Campina Grande, v. 15, n. 5, p. 435-442, 2011.

OSÓRIO, F. S.; BITTENCOURT, J. R. Sistemas Inteligentes baseados em Redes Neurais Artificiais aplicados ao Processamento de Imagens, In: I Workshop de inteligência artificial, 2000, apostila-seminário, Santa Cruz do Sul, UNISC – Universidade de Santa Cruz do Sul - Departamento de Informática, 2000.

PARENTE, H. N.; MAIA, M. O. Impacto do pastejo sobre a compactação dos solos com ênfase no Semiárido. **Revista Trópica – Ciências Agrárias e Biológicas**, v. 5, n. 3, p. 3-15, 2011.

PASSERINI, A. **Kernel Methods, multiclass classification and applications to computational molecular biology**. Tese (PhD) - Università Degli Studi di Firenze, 2004.

PEREIRA JÚNIOR, R. M.; FERREIRA, P. A.; MURI, P. C. C.; FERRARI, J. L. **Análise da resistência à penetração e da densidade do solo no perfil de um latossolo vermelho-amarelo**. In: XIV Encontro Latino Americano de Iniciação Científica e X Encontro Latino Americano de Pós-Graduação – Universidade do Vale do Paraíba. 2011.

PONTIL, M.; VERRI, A. Properties of Support Vector Machines. **Neural Computation**, Massachusetts, v. 10, n. 4, p. 955-974, mai. 1998.

RALISCH, R.; TAVARES FILHO, J. **Compactação do solo em sistema de plantio direto** – causas, efeitos e prevenção. In: Encontro Nacional de Plantio Direto na Palha, 8, 2002, Águas de Lindóia. Resumos. Ponta Grossa: Federação Brasileira de Plantio Direto na Palha, p.125-127, 2002.

RAWLS, W. J.; GISH, T. J.; BRAKENSIEK, D. L. Estimating soil water retention from soil physical properties and characteristics. **Advances in Soil Science**, v. 16, p.213-234, 1991.

REICHARDT, K. **Processos de transferência no sistema solo planta-atmosfera**. Piracicaba, CNEN – Fundação Cargill, 1975. 268p

REICHERT, J. M.; REINERT, D. J.; SUZUKI, L. E. A. S.; HORN, R. Mecânica do Solo. In: van LIER, Q. J. **Física do solo**. 1. Ed. Viçosa: Sociedade Brasileira de Ciência do Solo, 2010. Cap. 2, p. 29 - 102.

REINKE, M. Utilização de redes neurais artificiais aplicadas a mapeamento hidrogeológicos, 2008. Dissertação (Mestrado em Geologia) - Universidade do Vale do Rio dos Sinos. São Leopoldo, 2008.

REZENDE, S. O. “Sistemas inteligentes: Fundamentos e Aplicações”, Editora Manole Ltda, 2003.

RICHART, A.; FILHO, J.T.; BRITTO, O.R.; LLANILLO, R.F.; FERREIRA, R. Compactação do solo: causas e efeitos. **Semina: Ciências Agrárias**, Londrina, v. 26 n. 3, p. 321 – 344, 2005.

ROQUE, C. G.; CENTURION, J. F.; ALENCAR, G. V.; BEUTLER, N. A.; PEREIRA, G. T.; ANDRIOLI, I. Comparação de dois penetrômetros na avaliação da resistência à penetração de um Latossolo Vermelho sob diferentes usos. **Acta Scientiarum Agronomy**, v. 25, p. 53-57, 2003.

ROSA, D. P. **Comportamento dinâmico e mecânico do solo sob níveis diferenciados de escarificação e compactação**. 2007. 112 f. Dissertação (Mestrado em Engenharia Agrícola) – Universidade Federal de Santa Maria, Santa Maria, 2007.

ROSA, V. T. **Tempo de implantação do sistema plantio direto e propriedades físico-mecânicas de um latossolo**. 2009. Tese. 101p. (Doutorado em Ciência do Solo), - Universidade Federal de Santa Maria, Santa Maria, 2009.

ROSENBLATT, R. The Perceptron: A Probabilistic Model for Information Storage and Organization in the Brain. **Psychol. Rev.**65, 1958.

ROSOLEM, C.A.; FERNANDEZ, E.M.; ANDREOTTI, M.; CRUSCIOL, C.A.C. Crescimento radicular de plântulas de milho afetado pela resistência do solo à penetração. **Pesquisa Agropecuária Brasileira**, Brasília, v.34, n.5, p.821-828, 1999.

RÜCKNAGEL, J.; HOFMANN, B.; PAUL, R.; CHRISTEN, O.; HÜLSBERGEN, K.J. Estimating precompression stress of structured soils on the basis of aggregate density and dry bulk density. **Soil Tillage Research**, Amsterdam, v.92, n1-2, 213-220, 2007.

RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. Internal Representation by Error Propagation, in *Parallel Distributed Processing*. MIT Press, Cambridge, 1986.

RUSSEL, S. ; NORVIG, P. Artificial Intelligence, a modern approach. Series in Artificial Intelligence. **Prentice Hall**. 1995.

SALCHOW, E.; LAL, R.; FAUSEY, N.; WARD, A. Pedotransfer functions for variable alluvial soils in southern Ohio. **Geoderma**, Amsterdam, v.73, p.165-181, 1996.

SALIRE, E. V.; HAMMEL, J. E.; HARDCASTLE, J. H. Compression of intact subsoils under short-duration loading. **Soil & Tillage Research**, Amsterdam, v. 31, p. 235-248, 1994.

SANCHEZ, E. **Propriedades físicas do solo e produtividade de soja em sucessão a plantas de cobertura de inverno**. 2012. 48 p. Dissertação (Mestrado em Agronomia) – Universidade Estadual do Centro-Oeste, Guarapuava, 2012.

SANTOS, E. M. **Teoria e aplicação de support vector machines à aprendizagem e reconhecimento de objetos baseado na aparência**. 2002. 121 f. Dissertação (Mestrado em Informática) - Universidade Federal da Paraíba, João Pessoa, 2002.

SANTOS, F. L.; JESUS, V. A. M.; VALENTE, D. S. M. Modeling of soil penetration resistance using statistical analyses and artificial neural networks. **Acta Scientiarum. Agronomy**, Maringá, v. 34, n. 2, p. 219-224, 2012.

SAXTON, K. E.; RAWLS, W.R. Soil water characteristic estimates by texture and organic Matter for hydrologic solutions. **Soil Science Society of America Journal**, Madison, v. 70, p. 1569-1578, 1986.

SECCO, D. **Estados de compactação e suas implicações no comportamento mecânico e na produtividade de culturas em dois latossolos sob plantio direto**. 2003. Tese. 105 p. (Doutorado em Agronomia), - Universidade Federal de Santa Maria, Santa Maria, 2003.

SEVERIANO, E. C.; OLIVEIRA, G. C.; DIAS JUNIOR, M. S.; CASTRO, M. B.; OLIVEIRA, L. F. C.; COSTA, K. A. P. Compactação de solos cultivados com cana-de-açúcar: I -modelagem e quantificação da compactação adicional após as operações de colheita. **Revista Engenharia Agrícola**, Jaboticabal, v. 30, p. 404-413, 2010.

SEYBOLD, C.A.; HERRICK, J.E.; BREJDA, J.J. Soil resilience: a fundamental component of soil quality. **Soil Science**, New Brunswick, v.164, p.224-234, 1999.

SHAWE-TAYLOR, J.; CRISTIANINI, N. Kernel Methods for Pattern Analysis. New York, NY, USA: Cambridge University Press, 2004.

SILVA, A.; RAMOS, R.; SOUZA, L.; RODRIGUES, D.; MENDES, J. SIG – Uma plataforma para introdução de técnicas emergentes no planejamento urbano regional e de transportes: uma ferramenta 3D para análise ambiental urbana, avaliação multicritério, redes neurais artificiais. São Carlos: Editora dos Autores, 2004. 221p.

SILVA, A. J. N. **Alterações físicas e químicas de um argissolo amarelo coeso sob diferentes sistemas de manejo com cana-de-açúcar.** 2003. Tese. 120 p. (Doutorado em Ciência do Solo), - Universidade Federal do Rio Grande do Sul, Porto Alegre, 2003.

SILVA, A. R.; DIAS JUNIOR, M. S.; LEITE, F. P. Camada de resíduos florestais e pressão de pré-consolidação de dois latossolos. **Pesquisa Agropecuária Brasileira**, Brasília, v. 42, n. 1, p. 89-93, jan. 2007.

SILVA, D.; BARROS FILHO, A. F. B.; USP. Estatística. São Paulo, 2003.

SILVA, I. N. **Uma abordagem neuro-nebulosa para otimização de sistemas e identificação robusta.** 1997. 145 f. Tese (Doutorado em Engenharia Elétrica/Automação) – Universidade Estadual de Campinas, 1997.

SILVA, R. B.; LIMA, J. M.; DIAS JUNIOR, M. S.; SILVA, F. A. M. Alterações de propriedades físicas e hídricas de um latossolo vermelho distrófico pela adsorção de fósforo. **Revista Brasileira de. Ciência do Solo**, Viçosa, v. 25, p. 791-798, 2001.

SILVA, R. B.; DIAS JUNIOR, M. S.; SANTOS, F. L.; FRANZ, C. A. B. Influência do preparo inicial sobre a estrutura do solo quando da adoção do sistema plantio direto, avaliada por meio da pressão de preconsolidação. **Revista Brasileira de. Ciência do Solo**, Viçosa, v. 27, p. 961-971, 2003.

SILVA, R. B.; Lanças, K. P.; Cardoso, V. M. F.; Miranda, E. E. V. Atributos físicos, mecânicos e dinâmicos do solo como indicadores do impacto do cultivo e do tráfego em perímetros irrigados. **Revista Irriga**, Botucatu, v. 11, n. 3, p. 384-401, 2006.

SILVA, R.B.; IORI, P.; SILVA, F.A.M.; DIAS JÚNIOR, M.S. Modelagem e determinação do estado crítico de consolidação a partir da relação massa e volume em solos canavieiros. **Revista Ciências Agrárias**, v. 33, p. 376-389, 2010.

SILVA, R. P. **Atributos de Latossolos e produtividade da cana-de-açúcar em decorrência da diversificação de culturas no período de reforma do canavial.** 2013. 38 f. Dissertação (Mestrado em Agronomia) - Universidade Estadual Paulista, Jaboticabal, 2013.

SILVA, S. R.; BARROS, N. F.; COSTA, L. M. Atributos físicos de dois latossolos afetados pela compactação do solo. **Revista Brasileira de Engenharia Agrícola e Ambiental**, Campina Grande, v. 10, n. 4, p. 842-847, 2006.

SILVA, V. R.; REINERT, D. J.; REICHERT J. M. Suscetibilidade à compactação de um latossolo vermelho-escuro e de um podzólico vermelho-amarelo. **Revista Brasileira de. Ciência do Solo**, Viçosa, v. 24, p. 239-249, 2000.

SILVA, V. R.; REINERT, D. J.; REICHERT J. M.; SOARES J. M. fatores controladores da compressibilidade de um argissolo vermelho-amarelo distrófico arênico e de um latossolo vermelho distrófico típico. i - estado inicial de compactação. **Revista Brasileira de Ciência do Solo**, Viçosa, v. 26, p. 1-8, 2002.

SOANE, B. D.; VAN OUWERKERK, C. Soil compaction problems in world agriculture. In: SOANE, B. D.; OUWERKERK, C. van. (ed). **Soil compaction in crop production**. Netherlands : Elsevier, p.1-21, 1994.

SOANE, B.D. Process of soil compaction under vehicular traffic and means of alleviating it. In: LAL, R.; SANCHEZ, P.A.; CUMMINGS, R.W. **Land clearing and development in the tropics**. Rotterdam: Balkema Publisher, 1986. p.265-297.

SOARES, F. C. **Uso de diferentes metodologias na geração de funções de pedotransferência para a retenção de água em solos do Rio Grande do Sul**. 2013. 200 p. Tese (Doutorado em Engenharia Agrícola) – Universidade Federal de Santa Maria, Santa Maria, 2013.

SMOLA , A. J.; BARLETT, P. SCHÖLKOPF, B.; SCHUURMANS, D. Introduction to large margin classifiers. In A. J. Smola, P. Barlett, B. Schölkopf, and D. Schuurmans, editors, **Advances in Large Margin Classifiers**, MIT Press, p. 1–28, 1999.

SMOLA , A. J.; SCHÖLKOPF, B. **Learning with kernels**. The MIT Press, Cambridge, MA, 2002.

SOUZA, Z. M.; SILVA, M. L. S.; GUIMARÃES, G. L.; CAMPOS, D. T. S.; CARVALHO, M. P.; PEREIRA, G. T. Variabilidade espacial de atributos físicos em um Latossolo Vermelho distrófico sob semeadura direta em Selvíria (MS). **Revista Brasileira de Ciência do Solo**, Viçosa, v.25, p.699-707, 2001.

SOUZA, Z.M.; MARQUES JUNIOR, J.; PEREIRA, G.T. Variabilidade de atributos físicos do solo em diferentes formas do relevo sob cultivo de cana-de-açúcar. **Revista Brasileira de Ciência do Solo**, Viçosa, v.28, n.6, p.937-944, nov./dez. 2004.

STERNBERG, J. C.; STILLS. H. S.; SCHWENDEMAN, R. H. Spectrophotometric analysis of multi-component systems using the leastsquares method in matrix form. **Analytical Chemistry**, v. 32, p. 84-90, 1960.

STUMPF, L. **Atributos físicos e mecânicos de um solo construído em área de mineração de carvão em Candiota-RS, cultivado com diferentes espécies vegetais**. 2011. 124 p.. Tese (Doutorado em Agronomia) – Universidade Federal de Pelotas, Pelotas, 2011.

SUZUKI, L.E.A.S.; REINERT, D.J.; REICHERT, J.M.; LIMA, C.L.R. de. Estimativa da susceptibilidade à compactação e do suporte de carga do solo com base em propriedades físicas de solos do Rio Grande do Sul. **Revista Brasileira de Ciência do Solo**, Viçosa, v. 32, p. 963-973, 2008.

TAVARES, U. E. **Dependência espacial e comportamento físico e mecânico de um argissolo de tabuleiros costeiros de Pernambuco**. 2011. 64 f. Dissertação (Mestrado em Engenharia Agrícola) – Universidade Federal Rural de Pernambuco, Recife, 2011.

THOMÉ, A.C.G. **Redes Neurais** – uma ferramenta para KDD e Data Mining, 2002. Disponível em: <http://www.equipe.nce.ufrj.br/thome/grad/nn/mat/apostila_kdd_mbi>. Acesso em: 15 nov. 2014.

TIETJE, O.; HENNINGS, V. Accuracy of the saturated hydraulic conductivity prediction by pedo-transfer functions compared to the variability within FAO textural classes. **Geoderma**, Amsterdam, v. 69, p. 71-84, 1996.

TOMASELLA, J.; HODNETT, M.G.; ROSSATO, L. Pedotransfer functions for the estimation of soil water retention in Brazilian soils. **Soil Science Society of America Journal**, Madison, v.64, p.327- 338, 2000.

TORMENA, C. A.; ROLOFF, G.; SÁ, J. C. M. Propriedades físicas do solo sob plantio direto influenciado por calagem, preparo inicial e tráfego. *Revista Brasileira de Ciência do Solo*, Viçosa, v 22, p. 301-309, 1998.

TORMENA, C. A.; BARBOSA, M. C.; COSTA, A. C. S.; GONÇALVES, A. C. A. **Scientia Agricola**, v.59, n.4, p.795-801, 2002.

TORRES, E.; SARAIVA, O.F. **Camadas de impedimento do solo em sistemas agrícolas com a soja**. Londrina: Embrapa Soja, 1999. 58 p. (Circular Técnica, 23).

TRANGMAR, B.B.; YOST, R.S.; WADE, M.K.; UEHARA, G. Applications of geostatistics to spatial studies of soil properties. **Advances in Agronomy**, San Diego, v.38, n.1, p.45-94, 1985.

VALENÇA, M. J.S. Fundamentos das redes neurais: Exemplos em JAVA. 2ed. Olinda, PE: Livro Rápido, 2010. 386p.

VALENÇA, M. J.S. Aplicando redes neurais: um guia completo. Olinda, PE: Livro Rápido, 2005. 284p.

VALENÇA, M. J.S. Prevendo com redes neurais o Estado da arte. IN: XVI Simpósio Brasileiro de Recursos Hídricos, João Pessoa, 2005.

VAN GENUCHTEN, M.T. A closed form equation for predicting the hydraulic conductivity of unsaturated soils. **Soil Science Society of America Journal**, Madison, v. 44, p. 892-898, 1980.

VAPNIK, V. N. **The nature os statistical learning theory**. 1995. Springer-Verlag.

VAPNIK, V. N.. **Statistical Learnig Theory**. Canadá 1998.

VAPNIK, V. N. **The nature os statistical learning theory**. 1999. Springer-Verlag. 2 ed.

VAPNIK, V.; CHERVONENKIS, A., 1964. A note on one class of perceptrons. **Automation and Remote Control**, 25.

VEIGA, M.; HORN, R.; REINERT, D. J.; REICHERT J. M. Soil compressibility and penetrability of an Oxisol from southern Brazil, as affected by long – term tillage systems. **Soil and Tillage Research.**, v. 92, p. 104-113, 2007.

VEENHOF, D.W., MCBRIDE, R.A. Overconsolidation in agricultural soils. I. Compression and consolidation behaviour of remoulded and structured soils. **Soil Science Society of America Journal**, Madison, v. 60, p. 362–373, 1996.

VOGELMANN, E. S.; MENTGES, M.I.; REICHERT, J.M.; ROSA, D. P.; BARROS, C. A. P.; REINERT, D.J. Compressibilidade de um Argissolo Vermelho-Amarelo trafegado e escarificado. **Revista Ciência Rural**, Santa Maria, v. 42, n. 2, p. 291-297, 2012.

WAGENET, R.J.; BOUMA, J.; GROSSMAN, R.B. Minimum data sets for use of soil survey information in soil interpretive models. In: MAUSBACH, M.J. & WILDING, L.P., eds. Spatial variabilities of soils and landforms. Madison, Soil **Science Society of America**, 1991. (Special Publication, 28).

WERLANG, M. K. **Configuração da rede de drenagem e modelado do relevo: conformação da paisagem na zona de transição da bacia do paran na depresso central do rio grande do sul**. 2004. Tese. 206 p. (Doutorado em Cincia do Solo), - Universidade Federal de Santa Maria, Santa Maria, 2004.

WIDROW, B.; RUMELHART, D.E.; LEHR, M.A., “Neural Networks: Applications in Industry, Business and Science”, *Communications of ACM*, Vol.37, N.3, March, 1994.

WIDROW, B.; HOFF, M.E. Adaptive switching circuits. In: **IRE WESCON Convention Record** . New York: IRE Press, 1960. p.96-104.

WILLMONT, C. J. On the validation of models. **Physical Geography**, v. 2, n. 2, p. 184-194, 1981.

ZHAO, Y. On-line neural network learning algorithm with exponential convergence rate. **Electron. Lett.**, v. 32, n. 15, p. 1381–1382, 1996.

ZIEN, A.; RTSCHE, G.; MIKA, S.; SCHLTKOPF, B.; LENGAUER, T.; MULLER, K. R. Engineering support vector machine kernels that recognize translation initiation site. **BIOINF: Bioinformatics**. v.16(9), p. 799-807, 2000.

Zurada, J. M. **Introduction to Artificial Neural Systems**. PWS Publishing Company, Minesota, 1992.