**Universidade de São Paulo
Escola Superior de Agricultura “Luiz de Queiroz”**

**Aprendizado de máquina em dados estruturados para modelagem de
fenômenos hidráulicos em sistemas de microirrigação**

Wagner Wilson Ávila Bombardelli

Tese apresentada para obtenção do título de Doutor
em Ciências. Área de concentração: Engenharia de
Sistemas Agrícolas

**Piracicaba
2021**

Wagner Wilson Ávila Bombardelli
Engenheiro Agrícola

**Aprendizado de máquina em dados estruturados para modelagem de
fenômenos hidráulicos em sistemas de microirrigação**

versão revisada de acordo com a resolução CoPGr 6018 de 2011

Orientador:

Prof. Dr. **JOSÉ ANTÔNIO FRIZZONE**

Tese apresentada para obtenção do título de Doutor
em Ciências. Área de concentração: Engenharia de
Sistemas Agrícolas

Piracicaba
2021

Dados Internacionais de Catalogação na Publicação
DIVISÃO DE BIBLIOTECA - DIBD/ESALQ/USP

Bombardelli , Wagner Wilson Ávila

Aprendizado de máquina em dados estruturados para modelagem de fenômenos hidráulicos em sistemas de microirrigação / Wagner Wilson Ávila Bombardelli . -- versão revisada de acordo com a resolução CoPGr 6018 de 2011. -- Piracicaba, 2021 .

99 p.

Tese (Doutorado) -- USP / Escola Superior de Agricultura "Luiz de Queiroz".

1. Engenharia de Irrigação 2. Hidráulica 3. Análise dimensional 4. Rede neural artificial 5. Máquina de vetores de suporte 6. Boosting L. . I. Título.

AGRADECIMENTOS

À Universidade de São Paulo, especificamente à Escola Superior de Agricultura “Luiz de Queiroz” (ESALQ/USP) e ao Programa de Pós-Graduação em Engenharia de Sistemas Agrícolas, por oferecer a estrutura e o suporte técnico necessário à realização da pesquisa.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) e ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), pelo apoio financeiro a esta pesquisa, por meio do Instituto Nacional de Ciência e Tecnologia em Engenharia da Irrigação (INCT-EI).

Ao orientador prof. José Antônio Frizzone, por seus estimados conselhos inspiradores, orientação e confiança em mim depositada ao longo destes anos em que me acolheu na pós-graduação.

Ao co-orientador prof. Antonio Pires de Camargo, sempre atencioso e disposto em colaborar com ótimas sugestões, dicas, materiais e pizzas. Muito obrigado por ser um amigo e compartilhar todos seus conhecimentos com humildade.

À todos os funcionários do Departamento de Engenharia de Biosistemas e demais servidores públicos que participam colaborando com o desenvolvimento e funcionamento do ambiente acadêmico.

Ao Laboratório de Ensaio de Material de Irrigação (LEMI) por sua infraestrutura disponível, e todos os colegas que participaram com suas amizades, recomendações e apoio na condução dos experimentos.

À empresa RSB Plásticos por ter cedido os materiais necessários para a avaliação dos ensaios, em especial ao sr. Sílvio, que sempre se mantém apoiando as universidades.

Ao Laboratório de Hidráulica e Irrigação (LHI) por compartilhar materiais necessários aos ensaios hidráulicos.

À prof. Roseli F. Romero do Instituto de Ciências Matemáticas e de Computação (ICMC/USP) pelo encaminhamento da disciplina de Redes Neurais que introduziu o baldrame necessário para o estudo de aprendizado de máquina.

Ao prof. Luiz Henrique A. Rodrigues (Lique) da Faculdade de Engenharia Agrícola (FEA-GRI/Unicamp) por suas aulas ministradas de Mineração de Dados e Descoberta de Conhecimento em Banco de Dados que me fez explorar outros caminhos para tarefa de regressão.

Ao prof. Sérgio Nascimento Duarte por ter me supervisionado e instruído no período de estágio na disciplina de Hidrologia e Drenagem, destacando também a profa. Taitiány de Preparação Pedagógica que prestaram atenção para a construção de uma identidade docente.

Ao prof. Rubens Duarte Coelho por colaborar com suas sugestões no Exame de Qualificação.

Aos desenvolvedores das bibliotecas de código aberto, fóruns online e serviços gratuitos de hospedagem aplicados na condução da pesquisa.

ΕΠΙΓΡΑΦΕ

“Although this may seem a paradox,
all exact science is dominated by the idea of approximation. ”

Bertrand Russell

SUMÁRIO

Resumo	7
Abstract	8
Lista de Figuras	9
Lista de Tabelas	12
Lista de Abreviaturas e Siglas	13
Lista de Símbolos	14
1 INTRODUÇÃO	17
2 REVISÃO BIBLIOGRÁFICA	19
2.1 Perda localizada de carga	19
2.2 Análise dimensional e Teorema de Buckingham	19
2.2.1 Conectores iniciais	20
2.2.2 Gotejadores	21
2.3 Algoritmos de aprendizado supervisionado para tarefas de regressão	22
2.3.1 Redes neurais artificiais	23
2.3.2 Máquinas de vetores de suporte	25
2.3.3 Árvore de decisão	27
2.4 Validação cruzada	29
2.5 Pré-processamento	30
3 MATERIAL E MÉTODOS	33
3.1 Base de dados #1	33
3.1.1 Conectores iniciais (SC)	35
3.1.1.1 Tipo I	35
3.1.1.2 Tipo Iv	36
3.1.1.3 Tipo Y	36
3.1.2 Conectores de união (UC)	37
3.1.2.1 Tipo I	37
3.1.2.2 Tipo Iv	38
3.1.2.3 Tipo Y	38
3.1.2.4 Tipo T	39
3.2 Base de dados #2	40
3.2.1 Labirintos trapezoidais planos não-regulados	40
3.3 Modelagem	41
3.3.1 Análise Dimensional	41
3.3.2 Algoritmos de aprendizado de máquina	42
3.3.2.1 MLP	43
3.3.2.2 SVR	44
3.3.2.3 XGB	44
4 RESULTADOS E DISCUSSÕES	47
4.1 Bases de dados #1	47
4.1.1 Caracterização hidráulica	47
4.1.1.1 Conectores iniciais (SC)	47
4.1.1.2 Conectores de união (UC)	52
4.1.2 Estudo de caso	57
4.1.3 Modelos otimizados	58

4.1.4	Indicadores de erro	66
4.1.5	Desenvolvimento WEB	70
4.2	Base de dados #2	72
4.2.1	Modelos otimizados	72
4.2.2	Indicadores de erro	75
4.2.3	Desenvolvimento WEB	79
5	CONCLUSÃO	81
	REFERÊNCIAS	83
	Apêndices	89

RESUMO

Aprendizado de máquina em dados estruturados para modelagem de fenômenos hidráulicos em sistemas de microirrigação

O desempenho de um projeto de microirrigação está intimamente relacionado com a caracterização hidráulica de componentes do sistema. Buscando-se melhorar o desempenho de modelos matemáticos tradicionais, foram desenvolvidos e avaliados modelos computacionais baseados em redes neurais artificiais (MLP), máquina de vetores de suporte (SVR) e árvores de decisão conjuntas (XGB), a partir do aprendizado de bases de dados coletados em ensaios avaliando componentes de linhas laterais de irrigação: (a) conectores iniciais e de união, e; (b) emissores não-regulados. Os preditores considerados foram as propriedades do fluido, características geométricas e operacionais. Na base (a), um modelo genérico foi proposto para todos os conectores favorecendo o aprendizado mais completo possível. Os modelos tradicionais apresentaram erros superiores apontando que modelos computacionais podem proporcionar estimativas mais exatas em fenômenos relacionados à hidráulica de sistemas de microirrigação. O modelo MLP apresentou o melhor desempenho para os processos avaliados, embora necessite de um volume considerável de dados e uma calibração extensiva dos hiperparâmetros. O modelo SVR mostrou bom desempenho para base pequena, sendo predominantemente mais adequado o mapeamento por função de base radial. Contudo, é mais custoso computacionalmente e o estimador pode ser mais comprometido por ruídos. O modelo XGB cumpriu o custo computacional mais reduzido e forneceu uma boa acurácia, mas foi incoerente nos valores estimados em função de termos não correlacionados com os exemplos de treinamento. Os aplicativos WEB desenvolvidos sob código aberto facilitam o uso e a comparação de todos modelos de estudo e podem complementar ferramentas online para projetos e simulações.

Palavras-chave: 1. Engenharia de Irrigação 2. Hidráulica 3. Análise dimensional 4. Rede neural artificial 5. Máquina de vetores de suporte 6. Boosting L.

ABSTRACT

Machine learning in structured data of hydraulic phenomena in microirrigation systems

The performance of microirrigation project is closely related to the hydraulic characterization of fittings. In order to improve the performance compared to traditional models, machine learning models based on artificial neural networks (MLP), support vector machine (SVR) and ensemble of decision trees (XGB) were developed and validated. The databases collected in tests evaluated fittings of lateral irrigation lines: (a) start and union connectors, and (b) non-regulated emitters. The features considered were fluid properties, geometric and operational characteristics. In base (a), a generic model was proposed, supporting the most complete learning possible. The traditional models demonstrated larger errors indicating that the other models can provide more accurate estimates in phenomena linked to the hydraulics of microirrigation systems. The MLP model presented the best performance for the evaluated processes, although it requires a considerable amount of data and an extensive calibration of the hyperparameters. The SVR model revealed good performance for a small base, with the kernel function predominantly more appropriate by radial basis function. However, it is more computationally expensive, and the estimator may be more compromised by noise. The XGB model achieve the lowest computational cost and provided good accuracy but was inconsistent in the estimated values due to terms not correlated with the training examples. WEB applications developed under open-source code support the use and comparison of the models and can complement online tools for projects and simulations.

Keywords: 1. Irrigation Engineering 2. Hydraulic 3. Dimensional Analysis 4. Artificial Neural Network 5. Support Vector Machine 6. Gradient Boosting

LISTA DE FIGURAS

1	Representação esquemática de (a) corte longitudinal de um conector inicial acoplado na linha de derivação (<i>manifold</i>); (b) referenciamento das características geométricas da peça, e; (c) turbulência ocasionada pela inserção de conectores em tubulações, item (c) foi adaptado de VILAÇA <i>et al.</i> (2017).	20
2	Representação esquemática de um labirinto de gotejador com seção de escoamento retangular. Adaptado de LAVANHOLI (2019).	22
3	Exemplos no espaço de decisão de acordo com os algoritmos computacionais da pesquisa (ANN/MLP; SVM/SVR; e, DT/XGB), demonstrando um problema hipotético de classificação de duas dimensões (X_1 e X_2) para três classes. Fonte dos dados: Iris, de Fisher (1936).	23
4	Identificação da arquitetura de redes neurais artificiais abordada neste estudo, adaptado de JAIN <i>et al.</i> (1996).	24
5	Estrutura de redes neurais artificiais progressivas com múltiplas camadas ocultas (MLP), adaptado de AYACHI <i>et al.</i> (2012).	24
6	Exemplo de SVR. À esquerda: hiperplano representado pela função $f(x)$ com distância Euclidiana ε aos vetores de suporte e desvios de erros ξ_i e ξ_i^* . À direita: vista em corte no intervalo representado de $f(x)$ representando penalização dos erros. Adaptado de SMOLA e SCHÖLKOPF (2004); GUZMÁN <i>et al.</i> (2018); GRANATA (2019).	26
7	Árvore de decisão construída com complexidade hipotética a partir de dados de conectores iniciais de Bombardelli (2018). Indica-se a quantidade de observações contida em cada nó com sua respectiva média obtida pelo atributo meta (hf_L).	28
8	Esquematização do processo de validação cruzada do tipo 5-Fold, adaptado de PEDREGOSA <i>et al.</i> (2011).	30
9	Fluxograma de instrumentação da bancada de ensaios de perda de carga, em que: FT: medidor de vazão eletromagnético; TT: transmissor de temperatura; PT – transmissor de pressão; e, PDT – transmissor de pressão diferencial.	33
10	Estrutura de classificação dos tipos de conexões ensaiadas em seus grupos e classes formados com o conjunto de códigos informados pelo fabricante. Os conectores são apresentados na ordem: I_{SC} , Iv_{SC} , Y_{SC} , I_{UC} , Iv_{UC} , Y_{UC} e T_{UC}	35
11	Ilustração das conexões I_{SC} ensaiados por BOMBARDELLI (2018).	35
12	Ilustração das conexões Iv_{SC} ensaiadas.	36
13	Ilustração das conexões Y_{SC} ensaiadas.	37
14	Ilustração das conexões I_{UC} ensaiadas por BOMBARDELLI (2018)	38
15	Ilustração das conexões Iv_{UC} ensaiadas.	38
16	Ilustração das conexões Y_{UC} ensaiadas.	39
17	Ilustração das conexões T_{UC} ensaiadas.	39
18	Fluxograma de instrumentação da bancada de ensaios de perda de carga, adaptado de LAVANHOLI (2019). Em que, PT: transmissor de pressão.	40
19	Caracterização hidráulica dos conectores I_{SC} ensaiados por BOMBARDELLI (2018).	49
20	Caracterização hidráulica dos conectores Iv_{SC} ensaiados.	50
21	Caracterização hidráulica dos conectores Y_{SC} ensaiados.	51
22	Caracterização hidráulica dos conectores I_{UC} ensaiados por BOMBARDELLI (2018).	53
23	Caracterização hidráulica dos conectores Iv_{UC} ensaiados.	54
24	Caracterização hidráulica dos conectores Y_{UC} ensaiados.	55

25	Caracterização hidráulica dos conectores T_{UC} ensaiados.	56
26	Matriz de correlação de Pearson dos atributos presenciados na BD #1 quantificando a interação entre os atributos individuais e em grupos adimensionais.	59
27	Erros no conjunto de testes obtidos de acordo com classes de conectores e modelos NLS do tipo: ($\blacktriangle$) genérico, e; ($\bullet$) dedicado.	61
28	Erro mínimo observado variando as interconexões (a); e rede MLP adotada para base genérica de conectores (b), em que uma camada oculta com 32 nós e um bias se sobressaiu na simulação.	62
29	Modelos SVR com hiperparâmetros randômicos para simulação do balanço bias-variância, cujo Modelo 1* corresponde ao modelo otimizado adotado.	63
30	Hiperparâmetros do XGB simulados paralelamente, iniciado na ordem de, (a) quatro valores de encolhimento (η) para cinco níveis de profundidade da árvore; (b) critério para criação de um nó hierárquico acima do somatório mínimos dos pesos, e; (c) aleatorização da amostragem fracionada de instâncias (0,5, 0,75, 1) sob frações de atributos na árvore(0,4, 0,6, 0,8 e 1,0)	64
31	Custo do tempo de execução de acordo com os modelos computacionais e matemático; sendo (a) considerando o tempo total utilizado (hh:mm:ss) para o treinamento completo (erro em escala logarítmica), e; (b) restringindo a escala ao tempo demandado (mm:ss) pela maioria dos modelos (erro em escala linearizada)	65
32	Valores observados e estimados de perda localizada de carga (a) por modelos genéricos (matemáticos e computacionais) e histograma de erros (b). Em que, em (a), linha cinza: reta identidade, e; linha preta pontilhada: regressão linear com coeficiente de determinação.	67
33	Erro relativo (δ) dos modelos avaliados da BD #1 em domínio da frequência acumulada do conjunto de teste, com demonstração da porcentagem de dados para a condição de erro menor ou igual a 5% e 10% em 95% dos dados (δ_{95}).	68
34	Erro relativo médio da BD #1 obtido em intervalos da velocidade média de escoamento (V).	69
35	Pontuação de relevância dos atributos da BD #1 para divisão dos nós pelo algoritmo XGB.	70
36	Representação hipotética das curvas hf_L versus V pelo aplicativo WEB a partir de dados de teste condicionados no intervalo dos modelos limitados. Em que, NLS representa o modelo dedicado a cada tipo e NLS (*) o modelo genérico.	71
37	Matriz de correlação de Pearson dos atributos presenciados na BD #2 quantificando a interação entre os atributos individuais. Em que, (*) indica valores $< 0,001$	72
38	Erro mínimo observado variando as interconexões (a); e rede MLP adotada para base de emissores (b), em que uma camada oculta com 6 nós e um bias se sobressaiu na simulação.	73
39	Modelos SVR com hiperparâmetros aleatórios para simulação do balanço bias-variância com dados de teste da BD #2, cujo Modelo 1* corresponde ao modelo otimizado adotado.	74
40	Hiperparâmetros do XGB simulados paralelamente, iniciado na ordem de, (a) quatro valores de encolhimento (η) para cinco níveis de profundidade da árvore; (b) critério para criação de um nó hierárquico acima do somatório mínimos dos pesos, e; (c) aleatorização da amostragem fracionada de instâncias (0,5, 0,75, 1) sob frações de atributos na árvore (0,4, 0,6, 0,8 e 1).	74
41	Valores observados e estimados de vazão (a) e histograma de erros (b). Em que, em (a), linha cinza: reta identidade, e; linha preta pontilhada: regressão linear com coeficiente de determinação.	76
42	Erro relativo (δ) dos modelos avaliados da BD #2 em domínio da frequência acumulada do conjunto de teste, com demonstração da porcentagem de dados para a condição de erro menor ou igual a 5% e 10% e erro máximo em 95% dos dados(δ_{95})	77

43	Erro relativo médio da BD #2 obtido em intervalos da pressão de operação (h)	78
44	Pontuação de relevância dos atributos da BD #2 para divisão dos nós pelo algoritmo XGB.	78
45	Representação hipotética das curvas q <i>versus</i> h retornadas pelo aplicativo WEB, com (a) intervalo de 5 m, e; (b) intervalo de 2,5 m	79
A.1	Distribuição dos dados obtidos por ensaios dos conectores do tipo I _{SC}	90
A.2	Distribuição dos dados obtidos por ensaios dos conectores do tipo I _{SC/V}	91
A.3	Distribuição dos dados obtidos por ensaios dos conectores do tipo Y _{SC}	92
A.4	Distribuição dos dados obtidos por ensaios dos conectores do tipo I _{UC}	93
A.5	Distribuição dos dados obtidos por ensaios dos conectores do tipo I _{UC/V}	94
A.6	Distribuição dos dados obtidos por ensaios dos conectores do tipo Y _{UC}	95
A.7	Distribuição dos dados obtidos por ensaios dos conectores do tipo T _{UC}	96
A.8	Distribuição de todos dados obtidos por ensaios da BD #1	97
A.9	Distribuição dos dados obtidos por ensaios da BD #2	98
A.10	Modelos característicos de hf _L , dedicados aos códigos e às classes. Em que, hf _L : perda localizada por conectores iniciais (SC) e de união (UC), do tipo I sem ou com registros (Iv), do tipo T e do tipo Y, (m); V: velocidade média de escoamento, (m s ⁻¹); ν: viscosidade cinemática da água, (m ² s ⁻¹); D _L : diâmetro interno da lateral, (m); D _{in} e D _{out} : respectivos diâmetros de entrada e saída, (m); D _G : diâmetro da garganta no caso de registros, (m), L _{in} e L _{out} : respectivos comprimentos de entrada e saída, (m), Di: diâmetro interno médio $\frac{D_{in}+D_{out}}{2}$, (m); Li: comprimento médio dos trechos, $\frac{L_{in}+L_{out}}{2}$, (m) e; Lc: comprimento total, L _{in} +L _{out} , (m).	99

LISTA DE TABELAS

1	Informações geométricas das conexões I_{SC} ensaiadas por BOMBARDELLI (2018)	36
2	Informações geométricas das conexões $I_{V_{SC}}$ ensaiadas	36
3	Informações geométricas das conexões Y_{SC} ensaiadas	37
4	Informações geométricas das conexões I_{UC} ensaiadas por BOMBARDELLI (2018)	38
5	Informações geométricas das conexões $I_{V_{UC}}$ ensaiadas	38
6	Informações geométricas das conexões Y_{UC} ensaiadas	39
7	Informações geométricas das conexões T_{UC} ensaiadas	40
8	Valores extremos dos dados observados nos atributos da BD #2	41
9	Hiperparâmetros avaliados no algoritmo MLP	44
10	Hiperparâmetros avaliados no algoritmo SVR	44
11	Hiperparâmetros avaliados no algoritmo XGB	45
12	Resultados simulados indicando o peso dos conectores iniciais em linhas laterais.	57
13	Limitações dos modelos NLS dedicados às classes com seus valores mínimo e máximo de entrada	61
14	Hiperparâmetros otimizados ao modelo genérico de conectores	64
15	Hiperparâmetros otimizados ao modelo genérico de emissores	75

LISTA DE ABREVIATURAS E SIGLAS

ABNT	Associação Brasileira de Normas Técnicas
ANN	<i>Artificial Neural Network</i>
BD	Base de Dados
CART	<i>Classification and Regression Trees</i>
CV	<i>Cross-Validation</i>
DA	<i>Dimensional Analysis</i>
DE	<i>Differential Evolution</i>
DT	<i>Decision Tree</i>
GB	<i>Gradient Boosting</i>
ID3	<i>Iterative Dichotomiser 3</i>
I _{SC}	Conector inicial do Tipo I
ISO	<i>International Standard Organization</i>
I _{UC}	Conector de união do Tipo I
Iv _{SC}	Conector inicial com registro do Tipo I
Iv _{UC}	Conector de união com registro do Tipo I
IQR	<i>Interquartile Range</i>
KNN	<i>K-Nearest Neighbors</i>
LEMI	Laboratório de Ensaios e Material de Irrigação
LOO	<i>Leave-One-Out</i>
ML	<i>Machine Learning</i>
MLP	<i>Multi-layer Perceptron</i>
MLT	<i>Mass, Length and Time</i>
NBR	Norma Brasileira
NLS	<i>Nonlinear Least Squares</i>
R ²	Coefficiente de Determinação
RBF	<i>Radial Basis Function</i>
RF	<i>Random Forest</i>
RMSE	<i>Root Mean Square Error</i>
SC	<i>Start Connector</i>
SGD	<i>Stochastic Gradient Descent</i>
SVM	<i>Support Vector Machine</i>
SVR	<i>Support Vector Regression</i>
T _{UC}	Conector de união do Tipo T
UC	<i>Union Connector</i>
XGB	<i>Extreme Gradient Boosting</i>
Y _{SC}	Conector inicial do Tipo Y
Y _{UC}	Conector de união do Tipo Y

LISTA DE SÍMBOLOS

A	Área de escoamento (m^2)
A_g	Área de obstrução ocasionada pelo conector (i.e., $A_g = A - A_R$) (m^2)
A_r	Área efetiva de escoamento (m^2)
b	Bias (-)
C	Parâmetro regulador de penalidade do erro (-)
D_G	Diâmetro da garganta em conectores com registro (m)
D_h	Diâmetro hidráulico da seção de fluxo (m)
D_{in} e D_{out}	Diâmetros respectivos de entrada e saída do conector (m)
D_L	Diâmetro da linha lateral (m)
f	Fator de atrito de Darcy-Weisbach (-)
g	Aceleração gravitacional ($g = 9,81 \text{ m s}^{-2}$)
H	Altura do dente (mm)
h	Carga de pressão na entrada do labirinto (m)
hf	Perda distribuída de carga (m)
hf_C	Perda localizada de carga provocada por conectores iniciais na passagem lateral (m)
hf_e	Perda localizada de carga provocada por emissores no escoamento da linha lateral (m)
hf_L	Perda localizada de carga (m)
hf_{LL}	Perda de carga ocasionada na linha lateral ($hf_{LL} = hf + hf_e$), (m)
hf_T	Perda total de carga na linha lateral ($hf_T = hf_C + hf_{LL}$) (m)
H_K	Carga cinética do escoamento (m)
K_L ou ζ	Coefficiente de perda localizada (-)
l	Comprimento do fluxo central no canal do labirinto (m)
L_C	Comprimento total do conector (m)
L_E	Comprimento longitudinal do labirinto (mm)
L_{in} e L_{out}	Comprimentos respectivos de entrada e saída do conector (m)
L_{max}	Comprimento máximo da linha lateral considerando o critério de uniformidade (m)
N	Número de defletores do labirinto (-)
n	Número de pontos amostrados (-)
Q	Vazão de escoamento ($m^3 \text{ s}$)
q	Vazão do emissor ($L \text{ h}^{-1}$)
Q_0	Vazão de entrada na linha lateral ($L \text{ h}^{-1}$)
Re	Número de Reynolds (-)
Se	Espaçamento entre emissores (m)
T	Número de folhas na árvore (-)
t	Temperatura da água ($^{\circ}\text{C}$)
V	Velocidade média de escoamento ($m \text{ s}^{-1}$)
V_0	Velocidade média de escoamento na entrada do trecho de canalização analisado ($m \text{ s}^{-1}$)
V_r	Velocidade na seção de protrusão ($m \text{ s}^{-1}$)
w ou ω	Pesos ajustáveis (-)
W	Largura do canal (mm)
X	Variáveis de entrada
X_{min} e X_{max}	Valores respectivos de mínimo e máximo do atributo

X_s	Variáveis de entrada escalonadas
$\hat{y}$	Variável de saída estimada
y	Variável de saída observada
Z	Profundidade do canal (mm)
α	Ângulo do dente (rad)
α_i e α_i^*	Multiplicadores de Lagrange (-)
β_n	Coefficientes de ajuste de n -ésimos índices na relação funcional (-)
γ	Perda mínima para particionamento do nó (-)
γ'	Parâmetro de influência dos pontos no mapeamento RBF (-)
δ	Erro relativo entre valores observados e estimados $\left(\delta = 100 \frac{ y - \hat{y} }{y}\right)$ (%)
$\bar{\delta}$	Erro relativo médio entre o intervalo de pontos amostrados (%)
$\Delta L_{\max}$	Variação no comprimento da linha ocasionada por hf_C (%)
Δp	Decréscimo de pressão (Pa)
ε	Tubo epsilon de tolerância (-)
ε'	Rugosidade da superfície interna (m)
θ	Ângulo de entrada e saída do conector (rad)
λ	Regularização L_2 (<i>Ridge Regression</i>) (-)
λ'	Parâmetro de ajuste Box-Cox (-)
μ	Viscosidade dinâmica da água (Pa s)
ν	Viscosidade cinemática da água, em que $\nu = \frac{\mu}{\rho}$, ($m^2 s^{-1}$)
ν_j	Sinal de saída no nó de índice j (-)
ξ_i e ξ_i^*	Erros propriamente considerados em lados opostos ao hiperplano (-)
Π_n	Grupos adimensionais com n -ésimos índices (-)
ρ	Massa específica da água ($kg m^{-3}$)
Ω	Parâmetro de regularização que penaliza a complexidade do modelo (-)

1 INTRODUÇÃO

As linhas laterais de um sistema de microirrigação são condutos pressurizados que aplicam a água de irrigação através de emissores, procurando adequada uniformidade de aplicação. Para que se atinjam os níveis apropriados de uniformidade e qualidade no projeto de microirrigação é importante que se caracterize rigorosamente a hidráulica do sistema (YILDIRIM e AGIRALIOGLU, 2004). A variação de pressão se relaciona diretamente com a variação de vazão e, conseqüentemente, aos índices de uniformidade de emissão, de onde se estipulam valores admissíveis para uso nos dimensionamentos hidráulicos (ABNT ISO 9261, 2006).

As perdas de carga têm efeito significativo na variação de vazão dos emissores, dado que as pressões de operação comumente são baixas (FRIZZONE *et al.*, 2012). Vários são os estudos que demonstram a importância de se atentar às perdas localizadas de carga ao se projetar sistemas de microirrigação (AL-AMOUD, 1995; BAGARELLO *et al.*, 1997; JUANA *et al.*, 2002a,b; PROVENZANO e PUMO, 2004; YILDIRIM, 2007; YILDIRIM, 2010; RETTORE NETO *et al.*, 2009b,a; PERBONI *et al.*, 2015), sendo que negligenciá-las pode subestimar as perdas totais de carga comprometendo as estimativas de diâmetro e comprimento máximo das linhas laterais. Reduções na pressão de operação podem interferir na vazão e na sensibilidade à obstrução dos emissores (WEI *et al.*, 2006; ZHANG *et al.*, 2012; HAOSU *et al.*, 2016; FENG *et al.*, 2018; YU *et al.*, 2019). Um rigoroso dimensionamento de componentes do sistema de irrigação é crucial para o funcionamento e desempenho do sistema de irrigação.

Uma combinação de abordagens teóricas e experimentais é frequentemente necessária para desenvolver soluções práticas para problemas em Hidráulica e Mecânica de Fluidos (ZITTERELL *et al.*, 2014). A análise dimensional (DA) pode ser usada para resolver problemas na natureza de fluidos, pois é um método simples, claro e intuitivo para determinar a dependência funcional de grandezas físicas que influenciam um processo (VEKARIYA *et al.*, 2011). Nesse contexto, o método dos mínimos quadrados não-lineares (NLS) traz uma ferramenta bastante útil para o desenvolvimento de equações preditivas, além de que as variáveis físicas podem ser reduzidas em grupos adimensionais chamados termos Pi (II). O teorema de Buckingham Pi permite o planejamento de execuções experimentais e análise de medições por grupos adimensionais. Modelos multivariados baseados em NLS foram desenvolvidos com sucesso para estimar perda de pressão nas laterais de gotejamento (DEMIR *et al.*, 2007; PERBONI *et al.*, 2015), perda de carga em tubos lisos (FERRO, 1997), perda de carga nos filtros (PUIG-BARGUÉS *et al.*, 2005; YURDEM *et al.*, 2008; DURAN-ROS *et al.*, 2010; WU *et al.*, 2014), perdas localizadas em conectores de microirrigação (ZITTERELL *et al.*, 2014; VILAÇA *et al.*, 2017; BOMBARDELLI *et al.*, 2019), caracterização hidráulica de microtubos (VEKARIYA *et al.*, 2011), em tubos Venturi (SOBENKO *et al.*, 2019) e em labirintos de gotejadores (LAVANHOLI, 2019).

Existem outros métodos para solução de problemas de regressão propostos por algoritmos de aprendizado de máquina. Um sistema de aprendizado de máquina é treinado em vez de programado explicitamente. Considerando um aprendizado supervisionado, basta apresentar exemplos representativos de uma tarefa específica para que os algoritmos reconheçam sua estrutura estatística e, assim, identifiquem por si só as regras que automatizem tal tarefa (CHOLLET, 2018). Uma solução pode ser obtida por meio das redes neurais de múltiplas camadas (MLP). Este algoritmo vem sendo massivamente explorado pela alta capacidade no reconhecimento de padrões complexos e é encontrado facilmente em outros trabalhos correlatos de engenharia de irrigação. Por exemplo, para predição de perdas localizadas em emissores integrados (MARTÍ *et al.*, 2009; PERBONI *et al.*, 2014); simulação da distribuição de água por emissores (HINNELL *et al.*, 2010; ELNESR e ALAZBA, 2017); desempenho hidráulico nos labirintos dos canais de emissores (MATTAR e ALAMOUD, 2015); desempenho hidráulico nos filtros de areia (DURAN-ROS *et al.*, 2010; PUIG-BARGUÉS *et al.*, 2012); sistemas fotovoltaicos para irrigação (DURSUN e ÖZDEN, 2014); retenção de água no solo (NGUYEN *et al.*, 2017) e modelagem da evapotranspiração (KUMAR *et al.*,

2011).

Para tipos de dados organizados em uma estrutura tabulada outras possibilidades também se apresentam promissoras, como foi abordado por (GARCÍA NIETO *et al.*, 2016, 2018) em trabalhos que sucederam aos estudos supracitados com filtros de areia (DURAN-ROS *et al.*, 2010; PUIG-BARGUÉS *et al.*, 2012). GARCÍA NIETO *et al.* (2016) aproximaram com sucesso um modelo de regressão baseado na máquina de vetores de suporte (SVR) com núcleos radiais. GUZMÁN *et al.* (2018) delinearam uma regressão para a estimar a variabilidade da água subterrânea sob diferentes lâminas de irrigação. GUAN *et al.* (2013) trabalharam com a predição da salinização do solo em áreas irrigadas e obtiveram mais desempenho pelo SVR do que pela MLP e validaram a regressão na análise da condutividade elétrica do solo. VENKATANAGENDRA e MALIGELAUSSENAIAH (2017) obtiveram um modelo com estimativas mais exatas por vetores de suporte do que pela MLP em uma tarefa de classificação no sensoriamento de precipitação.

GARCÍA NIETO *et al.* (2018) apresentaram resultados de modelagem de perda de carga para filtro de areia pelo uso de um algoritmo baseado em árvore de decisão conjunta, utilizando a biblioteca XGBoost (CHEN e GUESTRIN, 2016). FAN *et al.* (2018b) compararam SVR com XGBoost (XGB) para prever a radiação solar global diária por meio da temperatura e da precipitação em climas úmidos subtropicais e concluíram que, considerando a precisão da predição, a estabilidade do modelo e a eficiência de processamento, o XGB foi altamente recomendado para estimar os índices diários. Há possibilidade de se classificar a importância das variáveis independentes do modelo por sua estrutura de condições aninhadas da árvore. Após obter sucesso nas competições de mineração de dados para dados estruturados, os autores confrontaram o desempenho com as redes convolucionais no aprendizado profundo (deep learning) de dados não-estruturados em problemas de percepção envolvendo imagem ou som. Nesse sentido, o aprendizado profundo e o XGB se apresentam atualmente como um estado-da-arte no sucesso de aprendizado de máquina (CHOLLET, 2018).

A literatura relata que os modelos matemáticos baseados em análise dimensional utilizando o Teorema de Buckingham apresentam desempenho satisfatório na modelagem de diversos processos relacionados à engenharia de irrigação (FERRO, 1997; PUIG-BARGUÉS *et al.*, 2005; DEMIR *et al.*, 2007; YURDEM *et al.*, 2008; DURAN-ROS *et al.*, 2010; WU *et al.*, 2014; ZITTERELL *et al.*, 2014; PERBONI *et al.*, 2015; VILAÇA *et al.*, 2017). Entretanto, vários são os processos no campo da hidráulica onde se assume que a variável de saída se relaciona com as variáveis de entrada por meio de uma função potencial múltipla, cujos coeficientes são ajustados a partir de dados experimentais. O pressuposto de que funções do tipo potencial se apliquem a todos os processos relacionados à Hidráulica é algo questionável e pode apresentar limitações. Neste contexto, a hipótese desta pesquisa é de que modelos computacionais baseados em algoritmos de aprendizado de máquina podem proporcionar desempenho superior a modelos matemáticos obtidos a partir de análise dimensional.

Diante disso, tal pesquisa apresentou os seguintes objetivos:

1. Desenvolver modelos matemáticos utilizando NLS e modelos computacionais baseados em algoritmos de aprendizado de máquina (MLP, SVR e XGB), para estimar (a) perdas localizadas proporcionadas por conectores utilizados em linhas laterais de sistemas de microirrigação; (b) vazão de labirintos de gotejadores planos, não regulados, de formato trapezoidal, considerando características geométricas e operacionais;
2. Avaliar indicadores de erro de predição, de capacidade de generalização e de custo computacional dos algoritmos de aprendizado de máquina nas tarefas de regressão; e
3. Desenvolver aplicativos WEB a fim de facilitar e difundir o uso dos modelos.

2 REVISÃO BIBLIOGRÁFICA

2.1 Perda localizada de carga

Usualmente a perda localizada de carga (hf_L) é determinada experimentalmente (Eq. 1) baseado no coeficiente de carga cinética (K_L), também conhecido como coeficiente de perda localizada de carga (PORTO, 1998; AZEVEDO NETO, 2015).

$$hf_L = K_L \frac{V_L^2}{2g} \quad (1)$$

Em que, hf_L : perda localizada de carga, (m), K_L : coeficiente de perda localizada, (-), V_L : velocidade média de escoamento na linha, ($m s^{-1}$), e; g é a aceleração gravitacional, ($9,81 m s^{-2}$).

O coeficiente K_L é adimensional e depende apenas do número de Reynolds (Re) e das características geométricas do componente considerado. Porém, K_L mostra-se menos dependente de Re na medida em que o escoamento assume regime turbulento. CARDOSO e FRIZZONE (2007) notaram o estabelecimento a partir de $20 \cdot 10^3$ em emissores “on-line”. Estudos com emissores integrados reportaram que esse coeficiente se manteve estabilizado com Re logo após de $10 \cdot 10^3$ (GOMES, 2009; RETTORE NETO *et al.*, 2009a). Esse comportamento independente permite um K_L constante para cada peça e conexão, independente do diâmetro da tubulação, da velocidade média de escoamento e natureza do fluido (função da temperatura), pois sua aplicação prática se dá predominantemente sob regime turbulento. Diante disso, o coeficiente K_L passa a ser função predominantemente da geometria de cada singularidade. Muitos autores afirmam que as perdas localizadas de carga têm um importante papel sobre as perdas totais de energia acarretando efeitos hidráulicos por vezes menosprezados (AL-AMOUD, 1995; BAGARELLO *et al.*, 1997; JUANA *et al.*, 2002a,b; PROVENZANO e PUMO, 2004; YILDIRIM, 2007; YILDIRIM, 2010; RETTORE NETO *et al.*, 2009b,a). AL-AMOUD (1995) analisou a protrusão de emissores “on-line” em tubos de polietileno de 13 e 25 mm e constatou que a hf_L ocasionada na linha provocou um acréscimo entre 5 a 32% nas perdas totais de energia. YILDIRIM (2007) relatou que desprezar o efeito de hf_L ocasionada pela protrusão de emissores pode levar a erros de até 25% em diâmetros de projeto e de até 7% em comprimento máximo de laterais. PROVENZANO e PUMO (2004) reportaram contribuição de hf_L entre 6,4 a 49,5% das perdas totais de energia em simulações para projetar laterais. RETTORE NETO *et al.* (2009b) observaram que as perdas totais aumentaram entre 24,5 a 50,8% quando era considerado a hf_L causada por gotejadores não coaxiais integrados a tubos de polietileno. PERBONI *et al.* (2015) analisaram tubo-emissores coaxiais integrados e verificaram que houve superestimativa de aproximadamente 16% no comprimento máximo da linha lateral desconsiderando hf_L por emissores não-regulados. Esses trabalhos mantêm atenção exclusiva aos emissores, mas conexões também são fontes de dissipação de energia e assumem uma parcela na contabilização da perda localizada de carga do sistema (VILAÇA *et al.*, 2017).

2.2 Análise dimensional e Teorema de Buckingham

Um modelo pode ser obtido combinando os termos envolvidos em grupos adimensionais para reduzir o número de variáveis. Esse tipo de abordagem é denominado de análise dimensional e a base de aplicação comumente utilizada aos problemas hidráulicos é obtida por intermédio do Teorema de Buckingham (ou Teorema dos Π), que é baseado na regra da homogeneidade dimensional conforme o postulado de BUCKINGHAM (1914). Ele nos informa que o fenômeno pode ser descrito por meio de grupos adimensionais com tamanho conforme o número de variáveis envolvidas, subtraído das grandezas básicas que as descrevem. Na Hidráulica as três grandezas fundamentais de massa, comprimento e tempo (MLT) são necessárias para representar dimensionalmente as variáveis do fenômeno. Tipicamente, a relação de variáveis independentes contera aquelas que são necessárias para descrever o sistema, como

a característica operacional (e.g., velocidade), propriedade do fluido (e.g., massa específica) e descrição geométrica (YONG *et al.*, 2004). Por fim, a relação funcional entre os parâmetros deve ser determinada experimentalmente.

Vários foram os problemas solucionados com sucesso utilizando-se dessa técnica na área de engenharia de irrigação. FERRO (1997) estudou os fatores responsáveis pela perda de carga em tubos lisos e explicou o fenômeno por meio de uma expressão adimensional. PUIG-BARGUÉS *et al.* (2005) obtiveram uma regressão do tipo potência como modelo de perda de carga em filtros comerciais de areia. DEMIR *et al.* (2007) estimaram hf_L em linhas laterais com emissores inseridos em diferentes espaçamentos. YURDEM *et al.* (2008) apresentaram um modelo que pode ser usado para determinar perdas de carga em filtros de disco. DURAN-ROS *et al.* (2010) estabeleceram equações para determinar a perda de carga em filtros comerciais de disco, tela e areia. VEKARIYA *et al.* (2011) produziram um modelo para estimativa da vazão em microtubos. ZITTERELL *et al.* (2014) estabeleceram a predição da perda localizada de carga na passagem lateral de conectores iniciais utilizados na microirrigação. PERBONI *et al.* (2015) modelaram a perda de carga ocasionada ao longo de linhas laterais com emissores cilíndricos. VILAÇA *et al.* (2017) propuseram equações que estimam a hf_L sob passagem direta e lateral em conectores iniciais disponíveis no mercado. Analogamente, BOMBARDELLI *et al.* (2019) desenvolveram modelos que estimam hf_L na passagem lateral para outros conectores iniciais comerciais com dados obtidos por ensaios de uma bancada automatizada (BOMBARDELLI *et al.*, 2017). SOBENKO *et al.* (2019) caracterizaram a vazão de injeção em tubos Venturi com um modelo desenvolvido que depende das propriedades do fluido, operacionais e geométricas do dispositivo. LAVANHOLI (2019) relacionou a vazão de saída de emissores não-regulados por meio de características operacionais e geométricas de labirintos trapezoidais planos.

2.2.1 Conectores iniciais

Conectores iniciais são componentes empregados para acoplar cada lateral na linha de derivação (*manifold*) correspondente (Figura 1). Perdas localizadas provocadas por conectores iniciais podem ser distinguidas em dois grupos: (i) perda localizada na passagem lateral (Figura 1a) – quando a água escoar através de um conector inicial (Figura 1b) há contrações e expansões na seção de escoamento, o que causa perdas localizadas de carga apenas na entrada da linha lateral; (ii) perda localizada na passagem direta (Figura 1c) – ao longo da linha de derivação, cada conector inicial obstrui parcialmente a seção de escoamento provocando perda localizada de carga, sendo que isso interfere nas características de escoamento e no dimensionamento da linha de derivação. No caso de conectores iniciais utilizados em microtubos para acoplar linhas laterais e emissores, o princípio mantém-se o mesmo.

Figura 1: Representação esquemática de (a) corte longitudinal de um conector inicial acoplado na linha de derivação (*manifold*); (b) referenciamento das características geométricas da peça, e; (c) turbulência ocasionada pela inserção de conectores em tubulações, item (c) foi adaptado de VILAÇA *et al.* (2017).

ZITTERELL *et al.* (2014) observaram um acréscimo de 5,16% na variação da vazão considerando as perdas localizadas na passagem lateral (do conector inicial e de microtubos) e a distribuída na linha lateral quando comparado apenas com as perdas distribuídas. VILAÇA *et al.* (2017) simularam a hidráulica de subunidades observando que hf_L na passagem lateral dos conectores representou de 0,48 a 7,31% das perdas totais de energia. Essa perda correspondeu em até aproximadamente um terço de todas perdas localizadas (entre 2,4 a 33,5%) além de ser constatado um decréscimo no comprimento máximo da linha lateral entre 0,5 a 3,0%. Segundo VILAÇA *et al.* (2017), tais efeitos podem ser significativos em simulações hidráulicas rigorosas que exigem estimativas de perda de carga.

ZITTERELL *et al.* (2014) desenvolveram um modelo (Eq. 2) baseado em análise dimensional para estimar a perda localizada que ocorre quando a água escoar através de pequenos conectores iniciais utilizados em microtubos (i.e. linha lateral de polietileno para um microtubo), cujo é válido para $0,36 \leq V_L \leq 7,58 \text{ m s}^{-1}$; $21,50 \leq L_C \leq 65,00 \text{ mm}$; $2,30 \leq D_{c_{out}} \leq 12,00 \text{ mm}$; $4,10 \leq D_L \leq 12,90 \text{ mm}$; $2,30 \leq D_{c_{in}} \leq 7,90 \text{ mm}$; e, $3.000 \leq Re \leq 66.000$ (-).

$$hf_L = 1,43 \cdot 10^{-4} \left(\frac{V^{2,00} L_C^{0,92} D_{out}^{2,16} D_L^{1,75}}{D_{in}^{5,74}} \right) \quad (2)$$

VILAÇA *et al.* (2017) desenvolveram seu modelo (Eq. 3) para cinco conectores iniciais de linhas laterais, que é válido nos seguintes intervalos adimensionais: $0,42 \leq \frac{D_{in}}{D_L} \leq 0,77$; $0,57 \leq \frac{D_{out}}{D_L} \leq 0,85$; $1,94 \leq \frac{L_C}{D_L} \leq 4,38$; $0,89 \leq \frac{A_R}{D_L^2} \leq 22,56$; e, $3.026 \leq Re \leq 94.536$

$$hf_L = 1,90 \cdot 10^{-2} \left(\frac{V^{2,06} D_L^{4,56}}{\nu^{0,06} D_{in}^{4,49}} \right) \quad (3)$$

Conectores iniciais disponíveis comercialmente para tubos de 13 e 16 mm foram avaliados por BOMBARDELLI (2018) e modelados através da análise dimensional (Eq. 4), sendo válido para os intervalos: $0,64 \leq V \leq 4,11 \text{ m s}^{-1}$; $16,43 \leq L_{in} \leq 22,93 \text{ mm}$; $27,56 \leq L_{out} \leq 43,28 \text{ mm}$; $7,82 \leq D_{in} \leq 9,79 \text{ mm}$; e, $9,66 \leq D_{out} \leq 12,36 \text{ mm}$.

$$hf_L = 3,40 \cdot 10^{-1} \left(\frac{V^{1,99} D_{out}^{3,22} L_{in}^{0,23} D_L^{0,35}}{D_{in}^{3,44} L_{out}^{0,37}} \right) \quad (4)$$

2.2.2 Gotejadores

Os emissores são pequenos dispositivos instalados ao longo das linhas laterais, responsáveis por dissipar a pressão e aplicar água uniformemente sob baixa vazão no solo (FRIZZONE *et al.*, 2012). Gotejadores projetados com base em canais denominados labirinto são comumente usados em sistemas de irrigação por gotejamento devido ao seu baixo custo, estrutura simples e desempenho hidráulico eficiente (YU *et al.*, 2019). Um labirinto consiste em um canal estreito com vários defletores que geram perdas de carga e garantem o controle da vazão na seção de descarga (WEI *et al.*, 2006). Nesse caso, há perdas localizadas resultantes de mudanças repentinas na direção do fluxo e dissipação por causa de vórtices, além de perdas por atrito nas seções retas do canal durante o fluxo do fluido (ZHANG *et al.*, 2012). À partir do estudo de ZHANG *et al.* (2012), deduzido a partir da equação de Darcy-Weisbach combinada com a expressão geral de perda localizada de carga, pode se observar (Eq. 5) quais variáveis impactam a queda de pressão entre a entrada e saída do labirinto.

$$\Delta p = N \left(f \frac{1}{D_h} + \zeta \right) \frac{\rho Q^2}{2A^2} \quad (5)$$

Em que, Δp : decréscimo de pressão no labirinto, (Pa); N : número de defletores, (-); f : fator de atrito de Darcy-Weisbach, (-); l : comprimento do fluxo central do canal, (m); D_h : diâmetro hidráulico da seção escoada, (m); ρ : massa específica da água, (kg m^{-3}); ζ : coeficiente de perda localizada em cada defletor, (-); Q : vazão no labirinto, ($\text{m}^3 \text{s}^{-1}$); e, A : área da seção de escoamento, (m^2).

Baseado nisso, LAVANHOLI (2019) projetou, fabricou e ensaiou 24 protótipos distintos, planos, não regulados, com labirintos trapezoidais e seção de fluxo retangular. Na Figura 2 são esquematizadas as características geométricas destes labirintos ensaiados.

Figura 2: Representação esquemática de um labirinto de gotejador com seção de escoamento retangular. Adaptado de LAVANHOLI (2019).

Informações de vazão foram obtidas em função dos parâmetros geométricos e operacionais sob temperatura da água constante (propriedade do fluido inalterada). LAVANHOLI *et al.* (2020) ajustaram o modelo matemático não-linear escolhendo empiricamente as variáveis de acordo com a interpretação física do fenômeno (Eq. 6). Esta equação é válida para variáveis entre: $45^\circ \leq \alpha \leq 60^\circ$; $0,5 \leq W \leq 1,3$ mm; $15, 18 \leq L_E \leq 888,42$ mm; $5 \leq h \leq 35$ m; $0,7 \leq H \leq 2,08$ mm; e, $0,5 \leq Z \leq 0,8$ mm.

$$q = 0,4041 \left(\frac{H}{W} \right)^{0,0115} \frac{\alpha^{0,5903}}{L_E^{0,0014} (WZ)^{0,0285}} h^{0,5412} \left(\frac{1}{\alpha} \right)^{0,4025} \quad (6)$$

Em que, q : vazão do emissor, (L h^{-1}); H : altura do dente, (mm); L_E : comprimento do labirinto, (mm); h : carga hidráulica na entrada do labirinto, (m); W : largura do canal, (mm); Z : profundidade do canal, (mm); e, α : ângulo do dente, (rad).

2.3 Algoritmos de aprendizado supervisionado para tarefas de regressão

O aprendizado de máquinas tem apresentado soluções eficazes para problemas complexos com descobrimento de conhecimento por meio dos dados experimentais. É mais comum o uso das redes neurais nas pesquisas científicas de dados estruturados (HINNELL *et al.*, 2010; MARTÍ *et al.*, 2009; KUMAR *et al.*, 2011; PUIG-BARGUÉS *et al.*, 2012; DURSUN e ÖZDEN, 2014; PERBONI *et al.*, 2014; MATTAR e ALAMOUD, 2015; ELNESR e ALAZBA, 2017; NGUYEN *et al.*, 2017). Entretanto, alguns outros algoritmos baseados em máquina de vetores de suporte e árvores de decisão vêm recebendo destaque nas publicações relacionadas a engenharia de irrigação atuais (GUAN *et al.*, 2013; GARCÍA NIETO *et al.*, 2016; FAN *et al.*, 2018a,b; GUZMÁN *et al.*, 2018; GARCÍA NIETO *et al.*, 2018). Diante disso, foram selecionados três potenciais algoritmos para suporte na tarefa de regressão baseado em redes neurais artificiais (ANN), máquina de vetores de suporte (SVM) e árvores de decisão (DT). A Figura 3 demonstra as diferenças através

de um problema hipotético de classificação de duas dimensões (X_1 e X_2) contendo 3 classes FISHER e MARSHALL (1936). Percebe-se que tais algoritmos delimitam seus próprios limites de contorno inerentes de seus mecanismos, os quais serão sucintamente descritos nos tópicos posteriores dedicados aos problemas de regressão.

Figura 3: Exemplos no espaço de decisão de acordo com os algoritmos computacionais da pesquisa (ANN/MLP; SVM/SVR; e, DT/XGB), demonstrando um problema hipotético de classificação de duas dimensões (X_1 e X_2) para três classes. Fonte dos dados: Iris, de Fisher (1936).

Um outro método simples não-paramétrico é obtido com uso dos K-vizinhos mais próximos (do acrônimo KNN) que pode resolver tarefas de regressão (BOTULA *et al.*, 2013; MODARESI e ARAGHINEJAD, 2014). Este método é conhecido como aprendizado preguiçoso (lazy learning), pois não aprende uma função discriminatória com os dados de treinamento, e sim memoriza-os de acordo com o parâmetro K de proximidade da vizinhança, o que o torna extremamente influenciado por ruídos.

2.3.1 Redes neurais artificiais

Inspirado no conceito biológico da neurociência, o algoritmo das redes neurais artificiais (ANN) foi aprimorado graças às informações contribuídas por profissionais de muitas áreas (SCHALKOFF, 2007), e suporta soluções para problemas complexos de classificação e regressão, para os quais a literatura reconhece os benefícios que essa técnica oferece em comparação às técnicas de modelagem estatística mais tradicionais (BENEDIKTSSON *et al.*, 1990; GARDNER e DORLING, 1998; SCHALKOFF, 2007). Especula-se que as ANNs possam ser ideais para a modelagem de dados agrícolas, uma vez que tais dados são conhecidos por serem complexos e muitas vezes possuem padrões não-lineares (MATTAR e ALAMOUD, 2015). Seu uso tem-se expandindo na engenharia de irrigação e foram aplicados com sucesso em casos como: simulação da distribuição de água sob gotejadores (HINNELL *et al.*, 2010; ELNESR e ALAZBA, 2017), perdas localizadas para emissores integrados (MARTÍ *et al.*, 2009), perdas de carga em emissores cilíndricos (PERBONI *et al.*, 2014), desempenho hidráulico no labirinto de emissores (MATTAR e ALAMOUD, 2015), volume de saída por filtros de areia de microirrigação (PUIG-BARGUÉS *et al.*, 2012), sistema de irrigação fotovoltaica (DURSUN e ÖZDEN, 2014), retenção de água no solo (NGUYEN *et al.*, 2017) e, modelagem de evapotranspiração (CHAUHAN e SHRIVASTAVA, 2009; KUMAR *et al.*, 2011).

O assunto redes neurais é bastante amplo e inclui discussões específicas para cada topologia (interconexões), características dos nós (ou neurônios) e estratégia para aprendizagem de padrões, localizando a classificação das arquiteturas de redes neurais artificiais abordadas no presente estudo pela Figura 4. No modo progressivo (*feedforward*) as interconexões entre as unidades de processamento são extensões hierárquicas das unidades Perceptron (ROSENBLATT, 1957) com nós em camadas que vão desde a entrada até a saída (SCHALKOFF, 2007).

Dado o interesse em problemas de regressão, foi mantido o foco acerca da aproximação de funções não-lineares por intermédio de redes progressivas de múltiplas camadas (MLP). MINSKY e PAPERT

Figura 4: Identificação da arquitetura de redes neurais artificiais abordada neste estudo, adaptado de JAIN *et al.* (1996)

(1969) mostraram que as interconexões do MLP aproximam praticamente qualquer função contínua a partir de três camadas (i.e., uma única camada oculta) (CYBENKO, 1992; HORNIK *et al.*, 1989; GUNTHER e FRITSCH, 2010). Além disso, o MLP não faz pressupostos anteriores sobre a distribuição dos dados (BENEDIKTSSON *et al.*, 1990). Isso permite modelar funções altamente não-lineares e generalizar quando apresentado com dados novos e não vistos. Essas características fazem do algoritmo uma atraente alternativa para o desenvolvimento de modelos de regressão (GARDNER e DORLING, 1998).

A arquitetura de uma rede MLP consiste em um sistema de neurônios interligados por pesos sinápticos ($w_{i,j}$), que simulam um mapeamento não-linear entre o vetor de entrada e o de saída. Surge uma direção no processamento de informações, por isso o MLP é classificado como uma rede neural progressiva (CHAUHAN e SHRIVASTAVA, 2009). Na Figura 5 é exemplificado uma rede MLP contendo vários nós de entrada ($x_1, x_2, \dots, x_n$), com vários nós ocultos ($j = 1, 2, \dots, J$) em várias camadas ocultas ($m = 1, 2, \dots, M$) com apenas um nó de saída (s_1), embora a complexidade das tarefas (e.g., classificação) possa vir a depender de mais nós ($s_1, s_2, \dots, s_n$) nessa camada (AYACHI *et al.*, 2012). Pela densidade de conexões podem ocorrer dificuldades na convergência de redes que usam números extrapolados de valores de entrada e saída (GUNTHER e FRITSCH, 2010). Unidades podem receber um estímulo adicional por meio de um peso extra de um nó ativo (conhecido por bias) e, usualmente, as redes são inicializadas com pesos aleatórios (BASHEER e HAJMEER, 2000).

Figura 5: Estrutura de redes neurais artificiais progressivas com múltiplas camadas ocultas (MLP), adaptado de AYACHI *et al.* (2012).

Os nós que recebem diretamente os valores que alimentam a rede constituem a camada de entrada. Os sinais dessa camada se propagam por meio de sinapses até a barreira de neurônios que formam a segunda camada, e assim sucessivamente, até a camada de saída. Os neurônios ocultos e de saída possuem o processamento iniciado matematicamente pela função integração (Eq. 7).

$$\nu_j = \sum_{i=1}^N w_{ji} \cdot x_i + b_j \quad (7)$$

Em que, ν_j : sinal de ponderação do nó; x_i : i -ésima variável de entrada; w_{ji} : i -ésimo peso sináptico na j -ésima camada; e, b_j : unidade bias na j -ésima camada.

Camadas internas são geralmente referidas como camadas ocultas. A linha pontilhada no centro dos neurônios (Figura 5) delimita as etapas de cálculo da soma ponderada com os pesos sinápticos (Eq. 7), e o cálculo de saída após a função de ativação, também conhecida como função de transferência (Eq. 8).

$$y_j = \varphi(\nu_j) \quad (8)$$

Em que, y_j : j -ésima saída do nó, e; $\varphi(\nu_j)$: transformação pela função de ativação após a ponderação recebida.

Se a função de transferência for linear (função identidade) a rede só será capaz de modelar funções lineares, o que não seria de muito interesse (HORNICK *et al.*, 1989; GARDNER e DORLING, 1998). Inclui-se assim outras funções não-lineares diferenciáveis como a função sigmóide ou tangente hiperbólica (HAN e MORAGA, 1995). O processo *feedforward* encerra-se na camada de saída retornando o resultado suposto ($\hat{y}$, Figura 5) de acordo com os dados de entrada e pesos das conexões (usualmente inicializados aleatoriamente). Entretanto, tratando-se de um aprendizado supervisionado, disponibiliza-se um resultado esperado para cada conjunto multivariado de entrada. Nesse sentido, a discrepância entre os resultados é obtida por meio de uma função objetivo a ser otimizada.

Uma rede consiste em muitas operações de tensores sequenciais diferenciáveis. Para computar o gradiente de uma função objetivo em relação aos pesos é utilizado a regra da cadeia de trás para frente, obtendo assim a contribuição de cada parâmetro no valor da perda. Esse complexo processo é designado de algoritmo *Backpropagation* e permite implementar a otimização do erro mínimo em um espaço de parâmetros variáveis (RUMELHART *et al.*, 1986; WERBOS *et al.*, 1990; LECUN *et al.*, 2015; CHOLLET, 2018). Os otimizadores são objetos de estudo na pesquisa para permitir que os pesos sinápticos manipulem a função objetivo com máxima eficiência (KINGMA e BA, 2014; RUDER, 2016).

2.3.2 Máquinas de vetores de suporte

A máquina de vetores de suporte (do acrônimo SVM) foi um algoritmo de aprendizado desenvolvido por CORTES e VAPNIK na década de 90 para ser capaz de lidar com tarefas supervisionadas de classificação. Seu princípio baseia-se em uma generalização de um classificador de margem máxima, mas que também se aplica para tarefas de regressão (SVR) (JAMES *et al.*, 2013; GUZMÁN *et al.*, 2018; GRANATA, 2019). Se os dados puderem ser perfeitamente separados usando um hiperplano, então existirá de fato um número infinito de hiperplanos dado que esse pode ser deslocado ou rotacionado sem entrar em contato com nenhuma das observações. Uma escolha sensata é o hiperplano de margem máxima que se encontra o mais distante possível da observação de treinamento mais próxima. Essa distância é a margem e condiciona a flexibilidade do modelo baseado em regras de decisão. Isto é, a classificação da observação de teste é determinada pelo lado onde os dados repousam diante do hiperplano de margem máxima (JAMES *et al.*, 2013).

Espera-se que haja uma flexibilidade na folga fornecida pela margem no treino que permita acomodar satisfatoriamente os dados de teste, em que é de boa prática o uso da validação cruzada dos parâmetros reguladores para decidir a tolerância do estimador. Uma exemplificação do módulo SVR em casos não-lineares é exibida pela Figura 6. Os valores que estão sobrepondo os limites ϵ são os chamados

vetores de suporte e os valores que os ultrapassam são considerados como erros propriamente ditos (ξ_i ou ξ_i^*). Erros não importam contanto que sejam menores que ε , enquanto desvios maiores são penalizados (Guzman et al., 2018).

Figura 6: Exemplo de SVR. À esquerda: hiperplano representado pela função $f(x)$ com distância Euclidiana ε aos vetores de suporte e desvios de erros ξ_i e ξ_i^* . À direita: vista em corte no intervalo representado de $f(x)$ representando penalização dos erros. Adaptado de SMOLA e SCHÖLKOPF (2004); GUZMÁN *et al.* (2018); GRANATA (2019).

Nesse sentido, a função a ser otimizada pelo algoritmo ε -SVR pode ser expressa matematicamente (Eq. 9). Como formulado por CORTES e VAPNIK (1995), tal equação está sujeita às restrições que devem ser satisfeitas para possibilitar a convergência dos pesos.

$$f(x) = \min_{w, b, \xi, \xi^*} \frac{1}{2} \|w\|^2 + C \sum_{i=1}^n (\xi_i + \xi_i^*), \quad \text{sujeito à} \begin{cases} y_i - w^T \varphi(x_i) - b \leq \varepsilon + \xi_i, \\ w^T \varphi(x_i) + b - y_i \leq \varepsilon + \xi_i^*, \\ \xi_i, \xi_i^* \geq 0, i = 1, \dots, n \end{cases} \quad (9)$$

Em que, $f(x)$: função do hiperplano; x_i e y_i : i -ésimos vetores de entrada e saída observados no treino; w e b : vetores de pesos e bias respectivos; ξ_i e ξ_i^* : variáveis de folga respectivas; C : parâmetro de penalidade do erro; $\varphi(x_i)$: transformação do i -ésimo vetor de entrada; ε : parâmetro que especifica o tamanho do tubo onde penalidades não são aplicadas; n : número de pontos amostrais.

Nota-se que os hiperparâmetros reguladores primordiais do algoritmo constitui-se no parâmetro C e ε . Além disso, em situações não-lineares realiza-se um mapeamento φ dos exemplos para um espaço de dimensão mais alta, e os vetores de treinamento são implicitamente transformados (SMOLA e SCHÖLKOPF, 2004). Esse argumento é fundamentado no teorema de Cover (1965), segundo o qual se afirma que em um problema de classificação de padrões complexos, os padrões não linearmente separáveis são mais prováveis de serem separados do que em espaços de dimensão mais baixa. Isto faz com que os exemplos tenham mais chances de se tornarem linearmente separáveis. Uma função *kernel* pode ser aplicada no mapeamento das observações não-lineares originais para um espaço acima no qual elas se tornam separáveis. Essa operação geralmente é computacionalmente mais barata que o cálculo declarado das coordenadas e é conhecida por *kernel trick* (JAMES *et al.*, 2013).

Deste modo, a função objetivo (Eq. 9) pode ser expressa de forma explícita (Eq. 10) introduzindo multiplicadores de Lagrange (α_i e α_i^*) que exploram as restrições de otimização e $\varphi(x, x_i)$ indicando a função φ atribuída para a transformação. O problema de otimização quadrática é resolvido para obter os valores de α_i e α_i^* na Eq. 10.

$$f(x, \alpha_i, \alpha_i^*) = \sum_{i=1}^n (\alpha_i - \alpha_i^*) \cdot \varphi(x, x_i) + b \quad (10)$$

Em que, α_i e α_i^* : multiplicadores de Lagrange $\in [0, C]$.

Para transformação dos dados em problemas não-lineares podem ser utilizadas funções do tipo polinomial, sigmoidal ou de base radial (RBF). A função RBF tem sido a escolha mais satisfatória em trabalhos correlatos por sua boa generalização e tolerância satisfatória aos ruídos de entrada obtidos (GARCÍA NIETO *et al.*, 2016; GUZMÁN *et al.*, 2018; FAN *et al.*, 2018a; GRANATA, 2019). Em comparação a rede MLP utiliza hiperplanos para particionar o espaço de entradas ao longo das camadas, enquanto que o mapeamento RBF utiliza hiper-elipsóides para a separação do espaço de decisão. Além disso, a função objetivo da rede MLP normalmente possui múltiplos mínimos locais, enquanto o SVR fornece uma solução única resultante da natureza convexa do problema de otimização (FAN *et al.*, 2018a; GUAN *et al.*, 2013).

A expressão matemática da RBF é apresentada pela Eq. 11. O parâmetro γ' pode ser interpretado como o inverso do raio de influência das amostras selecionadas pelo modelo como vetores de suporte (PEDREGOSA *et al.*, 2011). O padrão adotado por certos desenvolvedores utiliza γ' como uma relação ao número de atributos e a variância dos dados (PEDREGOSA *et al.*, 2011).

$$\phi(x, x_i) = e^{-\gamma' \|x_i - x\|^2} \quad (11)$$

Em que, x : centro dos pontos, γ' : parâmetro de influência dos pontos, onde $\gamma' \in \mathbb{R} \mid \gamma' > 0$.

Há, contudo, um custo excessivo do SVR quando aplicado em base de dados que contém um número alto de instâncias, pois seus requisitos de computação aumentam mais que quadraticamente com o número de vetores de treinamento (PEDREGOSA *et al.*, 2011). Assim, tais desenvolvedores consideram o uso da regressão SGD em bases com mais de 10.000 instâncias ao invés do SVR. No algoritmo SGD, o método iterativo faz uso do gradiente de descida estocástico (do acrônimo SGD) para otimização da função objetivo convexa de modo simples e com baixa onerosidade. Além disso, GONG e POELLABAUER (2017) encontraram resultados próximos comparando os métodos SVR e SGD para regressão dos dados.

2.3.3 Árvore de decisão

Uma árvore de decisão (DT) é um espaço condicionado por processo de indução para n possíveis situações, com aplicação tanto para problemas de classificação quanto de regressão. A condição primária é representada pela raiz (a árvore é tipicamente desenhada de ponta-cabeça), seguindo pelos nós (ramificações) até às folhas (ou nós terminais) as quais não contém filhos. Essa estrutura concede uma interpretação mais amigável para se visualizar as regras quando comparada com os outros estimadores. Na Figura 7 uma árvore é exemplificada contendo a fração de observações (%) que está contida em cada nó com a respectiva média contida do atributo meta (hf_L).

De acordo com LOH (2010), os algoritmos de árvore respondem duas questões: *como* será feita a separação dos nós e *quando* o processo será interrompido. Exemplifica-se os algoritmos ID3, CART e C4.5 como sendo os mais comuns na mineração de dados (SINGH e GUPTA, 2014). Praticamente todos os critérios de divisão se baseiam em um particionamento do nó a partir de instâncias que contenham o máximo de homogeneidade. Existem critérios baseados na redução da impureza de um nó; como exemplo de métricas de desigualdade se inclui entropia ou índice Gini. O suporte estatístico para a tomada de decisão se reduz progressivamente em ramos profundos e, com isso, os nós se tornam cada vez menos representativos de acordo com a complexidade do modelo. Por isso, recursos de poda controlados pela otimização de hiperparâmetros e seleção de atributos são utilizados em colaboração aos critérios de parada (JAMES *et al.*, 2013; SINGH e GUPTA, 2014).

Esse aninhado de condições que particionam o espaço de decisão acaba produzindo preditores fracos, pois uma pequena alteração nos dados tornaria as regras condicionadas inválidas e faria necessária

Figura 7: Árvore de decisão construída com complexidade hipotética a partir de dados de conectores iniciais de Bombardelli (2018). Indica-se a quantidade de observações contida em cada nó com sua respectiva média obtida pelo atributo meta (hf_L).

uma outra árvore. A coleção de várias árvores incrementa essa performance substancialmente e esse tipo de aplicação é conhecida como *Ensemble*. Uma técnica seria por meio do *Bootstrap Aggregation* (popularizado pela junção *Bagging*), que envolve a criação de múltiplas cópias dos dados originais de treino usando a técnica de *Bootstrap* (amostragem com reposição) e construindo paralelamente uma árvore independente para cada cópia, que são então combinadas produzindo um único modelo preditivo com menos variância através da maioria de votos. Uma extensão do *Bagging* é o método *Random Forest* que inclui uma etapa a mais, onde além do *Bootstrap* nos dados também se executa a seleção aleatória dos atributos (ao invés de todos preditores) produzindo várias árvores rasas (JAMES *et al.*, 2013).

Uma segunda opção de *Ensemble* é feita com crescimento sequenciais de árvores reforçando o resíduo passado, conhecido como *Boosting*. Nesse caso, cada árvore é uma versão modificada dos dados originais sem uso de *Bootstrap*. O *Gradient Boosting* (GB) se apresenta como uma extensão desse método com uso de minimização por gradiente para otimização de qualquer função objetiva diferenciável (FAN *et al.*, 2018a). Métodos baseados em GB são mais propensos ao ajuste excessivo (*overfitting*) para dados com muitos ruídos por sua natureza de reforçar o resíduo passado, além de possuírem mais hiperparâmetros controláveis do que pelo método de *Random Forest*. Contudo, quando bem calibrados, podem atingir resultados ainda mais acurados (OGUTU *et al.*, 2011). CHEN e GUESTRIN (2016) desenvolveram um aprimoramento do GB denominado como *Extreme Gradient Boosting* (referenciado como XGBoost ou XGB) baseado na estratégia CART. Regularizadores foram adicionados na estrutura deste algoritmo para prevenção de *overfitting* na construção do modelo. Adicionalmente, os cálculos foram reduzidos pela simplificação das funções de custo que permitem combinar os termos preditivos e de regularização mantendo uma eficiência computacional ótima, por meio de cálculos paralelos que são executados automaticamente para as funções no modelo XGB durante a fase de treinamento (FAN *et al.*, 2018a). Este desempenho faz do XGB a escolha de várias equipes vencedoras em competições de aprendizado de máquina permitindo que cientistas de dados explorem milhares de exemplos com mais rapidez e eficiência (SANDULESCU e CHIRU, 2016; VOLKOV *et al.*, 2017). De modo sucinto, o aprendizado reforça os resíduos sequencialmente baseado em estimadores fracos (FAN *et al.*, 2018a) e a expressão genérica para a predição na etapa t pode

ser apresentada como na Eq. 12.

$$f_i^{(t)} = \sum_{k=1}^t f_k(x_i) = f_i^{(t-1)} + f_t(x_i) \quad (12)$$

Em que, $f_i(x_i)$: aprendizado na etapa t ; $f_i(t)$ e $f_i^{(t-1)}$: predições na etapa t e $t - 1$; e, x_i : variável i -ésima de entrada.

Para evitar problemas de ajuste excessivo sem comprometer a velocidade computacional do modelo, o modelo XGBoost deriva a expressão analítica (Eq. 13) para avaliar a qualidade do modelo a partir da função original.

$$\text{Obj}^{(t)} = \sum_{k=1}^n l(y, \hat{y}) + \sum_{k=1}^t \Omega(f_i) \quad (13)$$

Em que, l : função objetivo entre valores observados (y) e estimados ($\hat{y}$), Ω : termo de regularização que penaliza a complexidade do modelo e é definido pela Eq. 14.

$$\Omega(f) = \gamma T + \frac{1}{2} \lambda ||\omega||^2 \quad (14)$$

Em que, γ : perda mínima necessária para o particionamento de mais uma folha; T : número de folhas na árvore; λ : parâmetro de regularização aos elementos de ω que fornecem pontuação às folhas.

Mais uma vez, os parâmetros descritos e correlatos podem ser otimizados com uso de processo não-enviesado como a validação cruzada. Maiores detalhes do GB podem ser obtidos pelo estudo de GARCÍA NIETO *et al.* (2018) e o princípio formal do XGB encontra-se documentado no artigo base dos desenvolvedores (CHEN e GUESTRIN, 2016).

2.4 Validação cruzada

Um meio para se declarar o desempenho de um modelo consiste em reservar um lote dos dados totais para teste, conhecido por *Hold-out*. Contudo, o acaso pode acabar por reservar exemplos típicos contidos nos dados de treino, fazendo com que as métricas de desempenho sejam consideradas ótimas para aquela condição em específico. Um método com mais imparcialidade pode ser obtido por meio de um procedimento denominado de validação cruzada (do acrônimo CV) de uso consagrado na literatura (PEDREGOSA *et al.*, 2011; JAMES *et al.*, 2013; HAYKIN, 2005). Se os dados totais disponíveis forem novamente particionados em mais um lote, o número de instâncias utilizadas no processo de treinamento é reduzido. Nesse sentido, os resultados são ponderados por uma escolha específica de validação entre a dicotomia treino e teste. Na abordagem básica, chamada CV *K-fold*, o conjunto de treinamento é dividido em K conjuntos menores.

Na Figura 8 se propôs esquematizar um processo de validação cruzada a partir do caso 5-Fold, e esclarecer melhor os termos utilizados no presente estudo, especialmente entre conjunto de teste e validação. Neste caso, 20% das instâncias de treino seriam reservadas progressivamente para validação do modelo a cada etapa do treinamento. Em outras palavras, o processo assegura que cada um dos lotes acabe atuando como agente de validação durante o processo de treino. No término do aprendizado retorna-se a média do erro de validação que declara o desempenho do treinamento de acordo com os hiperparâmetros avaliados, além de exprimir indicativos sobre a capacidade de generalização do modelo acima do conjunto reservado de teste (JAMES *et al.*, 2013). O processo de CV permite também aplicar um critério de parada do aprendizado conhecido por *Early Stopping*, que interrompe o treinamento quando o erro monitorado pelo conjunto de validação não mais se reduzir após um determinada tolerância (HAYKIN, 2005). Quando isto ocorrer, há sintoma de ajuste excessivo do modelo. Deste ponto em diante, o modelo

se ajustará aos ruídos presentes nas instâncias específicas de treino e não apenas aos padrões dos atributos, i.e., os dados não são mais aprendidos e sim decorados.

Figura 8: Esquematisação do processo de validação cruzada do tipo 5-Fold, adaptado de PEDREGOSA *et al.* (2011).

2.5 Pré-processamento

Muitos algoritmos de aprendizado de máquina podem se beneficiar do redimensionamento dos atributos para que todos tenham a mesma escala. Isso é importante para algoritmos de otimização usados no núcleo de algoritmos de aprendizado de máquina. O processo de padronização impede a dominância entre atributos que tornariam o estimador incapaz de aprender com outros recursos corretamente, e pode acelerar a descida do gradiente (PEDREGOSA *et al.*, 2011). um método simples e comum é obtido pela padronização da Eq. 15.

$$X_s = \frac{X_i - X_{\min}}{X_{\max} - X_{\min}} \quad (15)$$

Em que, X_s : valores padronizados; X_i : i -ésimo atributo preditor e seus valores mínimos ($X_{\min}$ e máximos ($X_{\max}$). X_s será compreendido no intervalo $[0, 1]$ mas isso pode ser modificado fazendo $X_s' = X_s (\max - \min) + \min$

A transformação dos dados pela função de potência Box-Cox (Eq. 16) pode tornar os atributos mais normais, pois consiste em encontrar um parâmetro de ajuste (λ') tal que os dados transformados se aproximem de uma distribuição gaussiana. Esse tipo de transformação é útil para modelar questões relacionadas à heterocedasticidade (variância não constante) ou outras situações onde a normalidade é desejada (BOX e COX, 1964). Por padrão, o algoritmo utilizado e desenvolvido por PEDREGOSA *et al.* (2011) também aplica a padronização Z-score (Eq. 17) que condiciona um desvio unitário e média zero aos dados transformados em função da média (μ) e o desvio-padrão (σ) dos atributos. Muitos elementos usados na função objetivo de um algoritmo de aprendizado (como o kernel RBF no SVM) assumem que todos os atributos estão centralizados em torno de zero e têm variação na mesma ordem (PEDREGOSA *et al.*, 2011).

$$x_i^{(\lambda')} = \begin{cases} \frac{x_i^{(\lambda')} - 1}{\lambda'} & \text{se, } \lambda' \neq 0, \\ \ln(x_i) & \text{se, } \lambda' = 0 \end{cases} \quad (16)$$

$$z = \frac{x_i - \mu}{\sigma} \quad (17)$$

Em que, x_i : i -ésimo dado de entrada do atributo; λ' : parâmetro de ajuste na transformação Box-Cox; μ e σ : média e desvio-padrão respectivos do atributo; e, z : padronização Z-score.

3 MATERIAL E MÉTODOS

O material explorado nessa pesquisa consiste em informações obtidas para microirrigação por meio de experimentos realizados no Laboratório de Ensaio de Material de Irrigação (LEMI) da ESALQ/USP. A metodologia aplicada para produção dos modelos envolveu compreensão dos fenômenos, entendimento dos dados, preparação dos dados, modelagem, validação e desenvolvimento dos modelos. A qualidade dos modelos é resultado da consistência dos dados coletados e da otimização dos hiperparâmetros de cada algoritmo.

3.1 Base de dados #1

Os modelos comerciais de conectores iniciais e de união foram fornecidos pela empresa RSB Plásticos LTDA, sediada em Campinas/SP. Os dados de perda localizada de carga foram obtidos por meio de ensaios em uma bancada automatizada desenvolvida pela equipe do LEMI, cuja estrutura de operação é descrita sucintamente na Figura 9.

Figura 9: Fluxograma de instrumentação da bancada de ensaios de perda de carga, em que: FT: medidor de vazão eletromagnético; TT: transmissor de temperatura; PT – transmissor de pressão; e, PDT – transmissor de pressão diferencial.

Sistemas automatizados asseguram estabilidade e repetitividade nas condições de ensaio, otimização do tempo de operação, redução das falhas ou imperfeições humanas e, consequentemente, conduz à melhor quantidade e qualidade nos resultados de ensaio. Maiores informações sobre a bancada de ensaios, bem como a instrumentação utilizada e rotina de procedimentos executados para validação de uso e aquisição dos dados se encontram detalhados no documento de BOMBARDELLI *et al.* (2017) e BOMBARDELLI (2018).

Para os ensaios hidráulicos com conexões contendo duas saídas foram tomadas precauções para assegurar a mesma vazão nas duas saídas. Nestes ensaios utilizaram-se duas válvulas proporcionais para ajuste das vazões à jusante das peças avaliadas. Foram utilizadas válvulas proporcionais da marca Slic®, modelo NACM-1, com diâmetro nominal de $\frac{1}{2}$ ".

Informações geométricas das amostras foram obtidas utilizando um paquímetro digital Starrett® (resolução de 0,01 mm) para obtenção da média na amostragem de 10 peças em cada modelo de classe. Valores da área de protrusão (A_g) foram obtidos por imagens analisadas em programa CAD e diâmetros internos (D_G) foram obtidos em um projetor ótico Starrett® HB-400. Esta mesma série mensurada foi utilizada como repetições nos ensaios.

Para obtenção da fração de perda localizada de carga (hf_L), a queda de pressão (Δp) presenciada em cada conjunto ensaiado teve a fração da perda distribuída ocasionada pelo tubo calculada pela Eq. de Darcy-Weibach com o fator de atrito (f) estimado pela Eq. 18 (SWAMEE, 1993). Considerou-se a rugosidade do polietileno como 8,116 m conforme declarado por ROCHA *et al.* (2017).

$$f = \left\{ \left(\frac{64}{Re} \right)^8 + 9,5 \left[\ln \left(\frac{\epsilon'}{3,7D_L} + \frac{5,74}{Re^{0,9}} \right) - \left(\frac{2500}{Re} \right)^6 \right]^{-16} \right\}^{0,125} \quad (18)$$

Em que, f : fator de atrito (-), Re : número de Reynolds (-) e ϵ' : rugosidade da superfície interna (m, $\epsilon' = 8,116\mu\text{m}$).

As BDs #1 são estruturadas por atributos preditores que representam efetivamente o atributo meta (hf_L). As características geométricas a serem utilizadas alternam de acordo com cada classe de conectores. De modo geral, os atributos preditores podem ser categorizados em:

- i. Propriedades do fluido: massa específica da água (ρ) e viscosidade dinâmica da água (μ);
- ii. Características operacionais: velocidade média de escoamento na seção considerada (V); e
- iii. Características geométricas: diâmetro da linha lateral (D_L), diâmetro de entrada e saída (D_{in} e D_{out}), respectivos comprimentos (L_{in} e L_{out}), ângulo formado entre a entrada e saída (θ), diâmetro de estreitamento na garganta nos registros (D_G) e, no caso de conectores iniciais, a área de protrusão da conexão causada no tubo de derivação (A_g).

Todavia, os valores característicos do fluido podem ser correlacionados com a temperatura da água. TANAKA *et al.* (2001) modelaram a massa específica da água (Eq. 19) para temperaturas entre 0 e 40°C sob pressão atmosférica ao nível do mar. PINTO *et al.* (2014) aplicaram os dados empíricos apresentados por AZEVEDO NETO (2015) com o modelo matemático sugerido por LIKHACHEV (2003), obtendo uma expressão da viscosidade cinemática em função da temperatura e da massa específica (Eq. 20).

$$\rho = 999,974950 \cdot \left[1 - \frac{(t - 3,983035)^2(t + 301,797)}{522528,9(t + 69,34881)} \right] \quad (19)$$

$$\nu = \frac{32,02566 \cdot 10^{-6}}{\rho} \cdot e^{\left(\frac{482,134866}{t + 119,886026} \right)} \quad (20)$$

Em que, ρ : massa específica da água (kg m^{-3}); t : temperatura da água ($^{\circ}\text{C}$); ν : viscosidade cinemática da água ($\text{m}^2 \text{s}^{-1}$).

Os atributos preditores da base permitem desenvolver informações como o regime de escoamento (caracterizado pelo número de Reynolds) e a relação de Borda-Bélangier pela razão de áreas entre seções. A Figura 10 apresenta uma estrutura de classificação dos tipos de conexões ensaiados para melhor introduzir os tópicos seguintes. Grupos paralelos foram formados por conectores iniciais e conectores de união (dos respectivos acrônimos SC e UC), classificados de acordo com a direção de escoamento (I, T ou Y), onde I pode possuir a presença de registros (Iv).

Figura 10: Estrutura de classificação dos tipos de conexões ensaiadas em seus grupos e classes formados com o conjunto de códigos informados pelo fabricante. Os conectores são apresentados na ordem: I_{SC} , Iv_{SC} , Y_{SC} , I_{UC} , Iv_{UC} , Y_{UC} e T_{UC} .

3.1.1 Conectores iniciais (SC)

3.1.1.1 Tipo I

A BD de conectores de tipo I_{SC} contém informações coletadas durante os ensaios de BOMBARDELLI (2018) e por terceiros (ZITTERELL *et al.*, 2014; VILAÇA *et al.*, 2017), que contabilizam ao todo 55.233 instâncias observadas em combinações de 20 modelos de conectores iniciais. Os conectores desse grupo podem ser caracterizados pelos atributos geométricos D_L , D_{in} , D_{out} , L_C e A_g .

Os conectores iniciais utilizados nos ensaios de ZITTERELL *et al.* (2014) são utilizados em conjunto com microtubos. Verifica-se que os diâmetros destes conectores assumem valores reduzidos e, com isso, podem ocasionar valores expressivos de perda localizada de acordo com a vazão. Os conectores iniciais ensaiados por VILAÇA *et al.* (2017) são utilizados em conjunto com tubos de polietileno com 13, 16, 20 e 26 mm de diâmetro. Ilustrações e valores dimensionais médios estão disponíveis nos documentos supracitados dos referidos autores. Por fim, na Figura 11 são apresentados os conectores ensaiados por BOMBARDELLI (2018), os quais são identificados conforme os códigos informados pelo catálogo do fabricante e possuem seus valores dimensionais médios apresentados na Tabela 1.

Figura 11: Ilustração das conexões I_{SC} ensaiadas por BOMBARDELLI (2018).

O diâmetro nominal de saída para os modelos 37, 46, 58, 59 e 186 é de 16 mm, enquanto o modelo 57 é destinado para tubos de 13 mm. O diâmetro de abertura no tubo rígido para os modelos 46 e 186 é de 12,70 mm, enquanto os modelos 37, 57, 58 e 59 necessitam de uma abertura de 17,50 mm para o pleno acoplamento com anéis de vedação.

Tabela 1: Informações geométricas das conexões I_{SC} ensaiadas por BOMBARDELLI (2018)

Código	A_g (mm ²)	D_{in} (mm)	D_{out} (mm)	L_{in} (mm)	L_{out} (mm)	L_C (mm)
37	207,40	9,79	12,24	16,83	43,28	60,11
46	209,23	7,95	12,36	21,63	40,83	62,46
57	187,34	9,64	9,66	18,47	30,77	49,24
58	174,45	9,69	11,65	16,43	31,43	47,86
59	211,76	9,72	11,68	16,83	31,37	48,20
186	245,08	7,82	11,60	22,93	27,56	50,49

3.1.1.2 Tipo Iv

A BD de conectores de tipo Iv_{SC} contém informações coletadas neste estudo e contabilizam 9.000 instâncias para cada um dos 3 modelos. Esses tipos são extensões dos conectores convencionais, os quais permitem controle da passagem de água e ocasionam um estreitamento na seção de articulação do registro (D_G). Isto confere mais uma variação na seção de escoamento e pode acarretar variações significativas no comportamento da perda localizada entre as repetições ensaiadas pelo processo de fabricação. Procurou-se utilizar peças visualmente similares quanto à questão de ausência de rebarbas. Os conectores Iv_{SC} ensaiados são ilustrados na Figura 12 identificando as nomenclaturas geométricas.

Figura 12: Ilustração das conexões Iv_{SC} ensaiadas.

Os diâmetros internos foram obtidos por intermédio de um projetor ótico Starrett® HB400 a partir de uma média de 5 peças. Os modelos 182 e 183 foram agrupados pois se distinguem apenas no mecanismo de fixação com o tubo (rosca lisa ou garra) mantendo as principais características geométricas. O diâmetro nominal de tubo para os modelos 150, 182 e 183 é de 16 mm enquanto o modelo 152 é destinado para tubos de 13 mm. O diâmetro de abertura no tubo rígido para todos modelos com anéis de vedação é de 17,50 mm. Embora os modelos 150 e 152 possuam valores geométricos internos muito semelhantes, eles são especificados para diâmetros diferentes de tubo. Isto é, o processo de fabricação altera a espessura na parede plástica dos conectores. Os valores dimensionais médios são quantificados na Tabela 2.

Tabela 2: Informações geométricas das conexões Iv_{SC} ensaiadas

Código	A_g (mm ²)	D_{in} (mm)	D_{out} (mm)	D_G (mm)	L_{in} (mm)	L_{out} (mm)	L_C (mm)
150	186,34	9,51	11,59	7,55	33,44	43,14	89,99
152	184,61	9,46	11,61	7,59	33,48	42,39	90,06
182/183	176,64	9,51	11,51	7,57	33,57	33,18	79,66

3.1.1.3 Tipo Y

A BD de conectores de tipo Y_{SC} contém informações coletadas no presente estudo e contabiliza 9.000 instâncias para cada um dos 4 modelos. Os atributos geométricos são nomeados pelas características de diâmetro e comprimento de entrada (D_{in} e L_{in}) e respectivas saídas (L_{out} e D_{out}). Os conectores de tipo Y permitem o acoplamento de duas linhas laterais de mesmo diâmetro nominal dispostas a uma abertura de 75°, que se projeta com ângulo (θ) de 142,5° em relação ao tubo de derivação. Os valores de ângulo

se mantêm constante para todos os demais componentes do tipo Y incluindo os conectores de união. Os conectores Y_{SC} ensaiados são ilustrados na Figura 13 identificando as nomenclaturas geométricas.

Figura 13: Ilustração das conexões Y_{SC} ensaiadas.

Os diâmetros nominais de saída para os modelos 181 e 237 são de 13 mm e os modelos 208, 234 e 235 são destinados para tubos de 16 mm. O diâmetro de abertura no tubo rígido para os modelos 234, 235 e 237 é de 17,50 mm, enquanto os modelos 181 e 208 necessitam de uma abertura de 25 mm para acoplamento com os anéis de vedação. Os modelos 234 e 235 foram agrupados pois também apresentam apenas alteração na fixação com o tubo. Os valores dimensionais médios são quantificados na Tabela 3.

Tabela 3: Informações geométricas das conexões Y_{SC} ensaiadas

Código	A_g (mm ²)	D_{in} (mm)	D_{out} (mm)	L_{in} (mm)	L_{out} (mm)	L_C (mm)
181	393,35	15,86	$9,42 \pm 0,08$	20,13	$46,51 \pm 0,30$	62,52
208	381,16	15,78	$11,51 \pm 0,05$	19,61	$47,19 \pm 0,16$	65,40
234/235	242,91	9,46	$11,25 \pm 0,04$	17,80	$47,90 \pm 0,14$	59,80
237	237,40	9,41	$9,40 \pm 0,01$	17,81	$46,47 \pm 0,24$	59,35

3.1.2 Conectores de união (UC)

3.1.2.1 Tipo I

A BD de conectores de tipo I_{UC} contém informações coletadas por BOMBARDELLI (2018) e contabiliza 9.000 instâncias para cada um dos 3 modelos. Esses modelos apresentam características geométricas simples para acoplamento de dois segmentos de linhas de um mesmo diâmetro nominal. Os conectores I_{UC} ensaiados são ilustrados na Figura 14 identificando as nomenclaturas geométricas.

Figura 14: Ilustração das conexões I_{UC} ensaiadas por BOMBARDELLI (2018)

Tabela 4: Informações geométricas das conexões I_{UC} ensaiadas por BOMBARDELLI (2018)

Código	$D_1 \sim D_2 = D_i$ (mm)	L_c (mm)
38	$11,96 \pm 0,22$	79,99
81	$9,43 \pm 0,24$	64,68
82/83	$11,41 \pm 0,05$	63,47

3.1.2.2 Tipo Iv

A BD de conectores de tipo Iv_{UC} contém informações coletadas neste estudo e contabilizam 9.000 instâncias para cada um dos 3 modelos. Os valores geométricos de ambas extremidades apresentam valores próximos. Os modelos 212, 213 e 223 diferem apenas pelo suporte de fixação do tubo. Os conectores Iv_{UC} ensaiados são ilustrados na Figura 15 identificando as nomenclaturas geométricas.

Figura 15: Ilustração das conexões Iv_{UC} ensaiadas.

O diâmetro nominal de tubo para os modelos 151, 212/213/223 é de 16 mm; já o modelo 153 é destinado para tubos de 13 mm. Os modelos 151 e 153 também possuem valores geométricos internos muito próximos, mas são destinados para diâmetros diferentes pela mesma questão de fabricação comentada para os conectores Iv_{SC} . Os valores médios são quantificados na Tabela 5.

Tabela 5: Informações geométricas das conexões Iv_{UC} ensaiadas

Código	$D_1 \sim D_2 = D_i$ (mm)	D_g (mm)	$L_1 \sim L_2$ (mm)	L_c (mm)
151	$11,59 \pm 0,06$	7,65	$43,42 \pm 0,25$	100,56
153	$11,54 \pm 0,04$	7,98	$43,26 \pm 0,09$	100,37
212/213/223	$11,48 \pm 0,01$	7,95	$32,75 \pm 0,07$	79,62

3.1.2.3 Tipo Y

A BD de conectores de tipo Y_{UC} contém informações coletadas neste estudo e contabiliza 9.000 instâncias para cada um dos 3 modelos. A entrada é assumida como a ramificação que possui ângulo obtuso com as demais aberturas, as quais compõem as seções de saída. Os conectores Y_{UC} são ilustrados na Figura 16 identificando as nomenclaturas geométricas.

Figura 16: Ilustração das conexões Y_{UC} ensaiadas.

Novamente, as características geométricas de ambas saídas são informadas pelo valor médio acrescido do desvio observado na mesma peça. Os diâmetros nominais de tubo para o modelo 180 é de 13 mm enquanto os modelos 204 e 232 são destinados para tubos de 16 mm. Os valores dimensionais médios são apresentados na Tabela 6.

Tabela 6: Informações geométricas das conexões Y_{UC} ensaiadas

Código	D_{in} (mm)	D_{out} (mm)	L_{in} (mm)	L_{out} (mm)	L_C (mm)
180	9,42	$9,37 \pm 0,02$	30,55	$45,97 \pm 0,15$	73,84
204	11,49	$11,45 \pm 0,03$	32,47	$49,51 \pm 0,02$	77,10
232	9,47	$11,56 \pm 0,03$	30,41	$48,74 \pm 0,23$	74,06

3.1.2.4 Tipo T

A BD de conectores de tipo T_{UC} contém informações coletadas nesse estudo e contabilizam 9.000 instâncias para cada um dos 2 modelos. Os valores dimensionais médios das saídas também são exibidos com o desvio observado. Os conectores T_{UC} são ilustrados na Figura 17 identificando as nomenclaturas geométricas.

Figura 17: Ilustração das conexões T_{UC} ensaiadas.

Os diâmetros nominais de tubo são idênticos para as aberturas de entrada e saída, sendo que o modelo 109 é destinado para tubos de 13 mm enquanto o modelo 164 é destinado para tubos de 16 mm. Os valores dimensionais médios são quantificados na Tabela 7.

Tabela 7: Informações geométricas das conexões T_{UC} ensaiadas

Código	$D_{in} \sim D_{out}$ (mm)	L_{in} (mm)	L_{out} (mm)
109	$8,85 \pm 0,02$	43,22	$42,55 \pm 0,11$
164	$11,51 \pm 0,01$	43,93	$42,63 \pm 0,07$

3.2 Base de dados #2

3.2.1 Labirintos trapezoidais planos não-regulados

LAVANHOLI (2019) projetou, desenvolveu e ensaiou 24 protótipos operando-os em 7 valores de pressão entre 50 e 350 kPa, em incrementos de 50 kPa. Nesse estudo, observa-se que tais protótipos podem ser separados em dois grupos, com labirintos que favorecem ou não a presença de vórtices bem desenvolvidos ao longo dos defletores. Os labirintos foram dimensionados para fornecer uma vazão próxima a $1,4 \text{ Lh}^{-1}$ sob pressão de 100 kPa LAVANHOLI *et al.* (2020). Gotejadores com vazão abaixo de $2,0 \text{ Lh}^{-1}$ são comumente utilizados em sistemas de microirrigação FRIZZONE *et al.* (2012). Para a condução dos ensaios foi utilizada uma bancada caracterizada por um circuito hidráulicamente fechado (Figura 18). Foram avaliados quatro protótipos simultaneamente, espaçados entre si em 0,20 m, sendo que a vazão de descarga foi determinada por massas coletadas em um intervalo de 30 minutos. Informações complementares, como rotina de ensaios e instrumentação empregada para coleta dos dados, podem ser consultadas diretamente na tese de LAVANHOLI (2019) ou no artigo dos autores (LAVANHOLI *et al.*, 2020).

Figura 18: Fluxograma de instrumentação da bancada de ensaios de perda de carga, adaptado de LAVANHOLI (2019). Em que, PT: transmissor de pressão.

Basicamente, a BD #2 contém 168 instâncias para o aprendizado supervisionado do atributo meta da vazão de descarga (q) em função de 6 atributos preditores, que podem ser divididos em:

- Características operacionais: pressão de operação (h); e
- Características geométricas: altura do dente (H), largura do canal (W), comprimento do labirinto (L), ângulo do dente (α) e profundidade do canal (Z).

As propriedades do fluido como massa específica (ρ) e viscosidade dinâmica (μ) foram mantidas constantes considerando uma temperatura d'água de $25^\circ\text{C} \pm 1^\circ\text{C}$ ($\rho = 997 \text{ kg m}^{-3}$ e $\mu = 8,91 \cdot 10^{-4} \text{ Pa s}$) em todas observações e, portanto, foram desconsideradas. Os valores limites da BD #2 podem ser resumidos pela Tabela 8 indicando os seus atributos extremos.

Os dados se mostraram consistentes não sendo necessário nenhuma correção prévia. Um gráfico 3D contendo a vazão de emissão (L h^{-1}), angulação do dente (rad) e pressão de operação (m), se encontra disponibilizado em <https://plot.ly/~wavila/63/> acompanhado dos dados completos da BD #2.

Tabela 8: Valores extremos dos dados observados nos atributos da BD #2

	H (mm)	W (mm)	L (mm)	α (rad)	Z (mm)	h (m)	q (L h ⁻¹)
$X_{\min}$	0,70	0,50	15,18	0,785	0,50	5	0,842
$X_{\max}$	2,08	1,30	888,42	1,309	0,80	35	3,063

3.3 Modelagem

É esperado obter um balanço ótimo entre a variância e o bias (ou viés) no ajuste do modelo. Uma métrica de uso comum (GUAN *et al.*, 2013; VILAÇA *et al.*, 2017; FAN *et al.*, 2018a,b; GARCÍA NIETO *et al.*, 2016, 2018; GRANATA, 2019) pode ser calculada pela raiz do erro médio quadrático (do acrônimo inglês RMSE). Este índice (Eq. 21) informa a raiz da variância de n observações expressando o quanto os valores preditos ($\hat{y}_i$) se distanciam dos valores observados (y_i).

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (21)$$

As simulações foram todas realizadas em uma máquina com processador de 2 x Intel(R)Core (TM) i7- 5500U CPU @ 2.40-3.0GHz e 16 GB de memória RAM. Uma rotina de treino e predição foi programada em Python (v. 3.6.12) para cada uma das técnicas de estudo utilizando de bibliotecas e versões citadas posteriormente para cada caso. O ambiente de programação utilizado foi o Atom (<https://atom.io>, v. 1.54), em ambiente Linux. Exploração dos dados e comparações extraordinárias foram conduzidas por meio da linguagem estatística R (v. 4.0.3) no ambiente RStudio. Processamento gráfico (GPU) não foi habilitado neste caso, sendo utilizado apenas CPU. Utilizou-se o mesmo lote de dados para treino e teste na construção e análise não-enviesada de modelos matemáticos e computacionais.

3.3.1 Análise Dimensional

Nas BDs #1 a variável dependente é exclusivamente a queda de pressão (Δp). Intuitivamente, as variáveis independentes são consideradas baseadas no estudo do fenômeno físico (Eq. 22) e se relacionam com as características operacionais, propriedades da água, e características geométricas intrínsecas de cada componente.

$$\Delta p = \Phi(V, \rho, \mu, D_{\text{in}}, D_{\text{out}}, D_G, L_{\text{in}}, L_{\text{out}}, D_L, \theta) \quad (22)$$

Para criação dos grupos adimensionais foi atribuído a sequência de variáveis repetida como sendo: ρ , V e D_L . Tais variáveis repetidas passam a ser combinadas sistematicamente com as demais variáveis, a fim de definir quais serão os termos Π . Assim, os grupos adimensionais foram estabelecidos e podem ser expressos pela Eq. 23. O termo α é adimensional pois pode ser expresso como uma razão de comprimento do arco pelo raio.

$$\frac{\Delta p}{\rho V^2} = \Phi \left(\frac{\rho V D_L}{\mu}, \frac{D_{\text{in}}}{D_L}, \frac{D_{\text{out}}}{D_L}, \frac{D_G}{D_L}, \frac{L_{\text{in}}}{D_L}, \frac{L_{\text{out}}}{D_L}, \theta \right) \quad (23)$$

Um modelo matemático multivariado de potência (Eq. 24) foi proposto para relacionar os grupos adimensionais. Tal relação funcional tem sido empregada com sucesso em processos de modelagem relacionados ao fluxo de fluidos em aplicações da engenharia de irrigação (VEKARIYA *et al.*, 2011; ZITTERELL *et al.*, 2014; VILAÇA *et al.*, 2017; BOMBARDELLI *et al.*, 2019; SOBENKO *et al.*, 2019). Os coeficientes de ajuste ($\beta_1, \beta_2, \dots, \beta_n$) foram otimizados por meio dos Mínimos Quadrados Não-Lineares (NLS) utilizando do pacote *DEoptim* fornecido para linguagem R (ARDIA *et al.*, 2010).

$$\Pi_1 = \beta_1 \Pi_2^{\beta_2} \Pi_3^{\beta_3} \dots \Pi_n^{\beta_n} \quad (24)$$

No caso da BD #2 foi utilizado o modelo matemático desenvolvido por LAVANHOLI *et al.* (2020) (Eq. 6), que propuseram uma relação funcional aprimorada por tentativa e erro a partir da mesma base de dados utilizada neste estudo.

3.3.2 Algoritmos de aprendizado de máquina

Os módulos de algoritmos MLP, SVR e XGB foram selecionados para as tarefas de regressão por possuírem seus próprios mecanismos para mapeamento do espaço de decisão na criação de estimadores, diante dos quais recebem a atenção no meio científico pela solução bem-sucedida dos problemas reais complexos. Os modelos finais permitem o carregamento por aplicativos computacionais que possam vir a facilitar o uso prático.

No caso da BD #1, nos ensaios experimentais em bancada coletaram-se 30 pontos para cada uma das 15 condições da válvula proporcional de incremento da vazão, e mais 15 condições reduzindo a vazão (i.e., 900 instâncias amostradas por peça) com 10 repetições para cada modelo do lote. Há algoritmos que se favorecem de mais dados similares para aproximação das variáveis contínuas dentro do intervalo amostrado (TORGO *et al.*, 2015; ARSLAN *et al.*, 2019). Existe um método para adição de “dados sintéticos” a partir da proximidade (conhecida como *oversampling*) em dados multivariados desbalanceados para tarefas de regressão (TORGO *et al.*, 2013). Em processamento de imagens (redes convolucionais), onde os dados costumam ser custosos, adicionam-se novas imagens no lote de treinamento a partir de rotações, translações, filtros, e recursos similares a partir das imagens coletadas (conhecido como *data augmentation*).

Por outro lado, a robustez do modelo é favorecida na medida em que se variem as condições geométricas, operacionais e do fluido. As classes de peças podem ser diferenciadas pelo atributo ângulo (θ , vide Eqs. 22 e 23) formado entre a entrada e saída do escoamento e possuem valores de 90° (T), 142,5° (Y) e 180° (I). Vale ressaltar que o ângulo de abertura nas ramificações de tipo Y se mantém constante para todas as peças de mesma arquitetura. Experiências informam que A_g não é significativo nas perdas localizadas por passagens laterais (VILAÇA *et al.*, 2017; SOBENKO *et al.*, 2019), acrescentando-se ao fato de que sua mensuração é a mais onerosa dentre as demais. Dito isso, desconsiderou-se este atributo nos conectores iniciais. Incluiu-se o atributo de D_G para todos as classes, que se mantém como D_{in} quando não há presença da válvula de registro. Logo, o comprimento L_G foi descartado haja visto que a seção age apenas como um orifício que proporciona uma contração nas linhas de corrente (MARTIN, 1974; BULLEN *et al.*, 1987; GUO *et al.*, 2010). Na união, os comprimentos L_{in} e L_{out} foram convencionados como a metade dos respectivos comprimentos totais (L_C) pois possuem seções uniformes não-cônicas. Nos dados de terceiros, onde não constam os valores fracionados de comprimento, L_{in} e L_{out} foram aproximados pelos valores de L_C baseados na proporção dos conectores ensaiados pelo presente estudo. Com isto, foi constatado uma proporção média de 35,8% exercida pelo L_{in} em razão do L_C . Um padrão no atributo L_{in} pode ajudar os modelos na identificação dos grupos de conectores iniciais e conectores de união. Finalmente, as características geométricas passam a ser: $D_{in}, D_{out}, D_G, L_{in}, L_{out}, \theta$; e podem ser atendidas por todas as bases.

Houve apenas remoção de valores extremos no atributo meta (hf_L) que ultrapassassem os limites de 1,5 vezes o tamanho do intervalo de interquartis (do acrônimo IQR) a partir do quartil mais próximo. Deste modo, foram descartadas apenas 180 observações (reduzindo menos de 0,08%), restando ainda 226.060 instâncias somando todas as sub-bases. O aprendizado considerou 70% dos dados aleatoriamente selecionados para treino acompanhado do processo de validação cruzada do tipo K-Fold com 3 desdobramentos ($K=3$). Na etapa de pré-processamento da BD #1, os atributos preditores foram

padronizados para o intervalo $[0, 1]$ (Eq. 7). O atributo meta contém apenas números reais positivos e sofreu transformações a partir da função de potência Box-Cox (Eq. 8) por sua variância não constante em relação a média.

No caso da BD #2 há poucas instâncias, o que não é recomendado para treinamentos que exigem alta complexidade (HAYKIN, 2005). Neste caso, optou-se por utilizar aleatoriamente apenas 20% dos dados para teste. Deste modo, 32 instâncias foram destinadas para teste, o que suporta minimamente a análise de erros e mantém um balanço satisfatório para o treino. A validação por *Leave-One-Out* (LOO) é uma extensão do K-Fold, onde o processo é acima de todas instâncias de treino exceto uma para validação (i.e., K é o número de instâncias menos um). Embora interessante para bases pequenas, é oneroso computacionalmente e acaba inviabilizando o procedimento de todos testes para todos algoritmos. Por isso, procedeu-se o 10-Fold alterando a distribuição de volume nos lotes de treino e teste. Somente os atributos preditores passaram pelo pré-processamento e foram padronizados para o intervalo $[0, 1]$ (Eq. 7).

3.3.2.1 MLP

Utilizou-se a biblioteca *Tensorflow* de código aberto (ABADI *et al.*, 2016) com uso do pacote base para a interface Keras (CHOLLET, 2018) para manipulação dos tensores. Estabeleceu-se que as redes de múltiplas camadas sejam inicializadas com pesos aleatórios distribuídos uniformemente numa pequena faixa de $\pm 5 \cdot 10^{-4}$ para evitar a saturação prematura do neurônio. Um neurônio foi acrescentado na primeira camada oculta atuando como bias.

A inicialização do módulo aleatório é produzida por meio de uma semente; trata-se de um artifício que permite a reprodutibilidade de números aleatórios permitindo que os erros possam ser equiparados. Os ensaios avaliaram cinco números distintos de sementes a fim de possibilitar mais condições de inicialização da rede (pesos e instâncias), de onde foram selecionados os lotes de treino e teste mais adequados para serem utilizados pela MLP e posteriormente pelas demais técnicas.

Ensaio preliminares foram executados para pré-definir alguns hiperparâmetros por meio de validação cruzada através de um método de varredura aleatória de busca. Esta rotina de busca é destacada como eficiente por retornar resultados próximos ao método de varredura completa acrescido de um tempo de processamento mais rápido (PEDREGOSA *et al.*, 2011; BENGIO, 2012). Reduziu-se suavemente a taxa de aprendizado para $2,5 \cdot 10^{-4}$ tornando o treinamento mais preciso, porém mais lento, com um tamanho de lote de 256 observações e 2.000 épocas. O otimizador Adam destacou-se dentre os demais para minimização da função objetivo, pois é menos custoso computacionalmente e proporcionou mais acurácia dentre os demais; mesmo com os parâmetros padrões explicitados pelos desenvolvedores (KINGMA e BA, 2014). Houve emprego da função de ativação (Eq. 8) do tipo tangente hiperbólica, que é matematicamente expressa pela Eq. 25 e trata-se de uma versão escalonada da função sigmóide com imagem ampliada para $[-1,1]$, sendo de uso comum em soluções de engenharia (ZANETTI *et al.*, 2007; MATTAR e ALAMOUD, 2015).

$$\varphi(\nu) = \frac{1 - e^{-2\nu}}{1 + e^{-2\nu}} \quad (25)$$

A avaliação da rede foi feita com neurônios variando de 5, 6, 7, 8, 16, 24, 32, 48 e 64 nós para arquiteturas de uma camada, com exclusão de 5, 6 e 7 nós para duas a três camadas ocultas contendo o mesmo tamanho de nós em cada camada (Tabela 9). Os valores otimizados de conexões foram obtidos alterando o número de camadas e nós, enquanto era analisado o erro no conjunto de teste (BENGIO, 2012). LAROCHELLE *et al.* (2009) reportam que a topologia com tamanhos iguais de unidades nas camadas ocultas se sobressaiu quando comparado com estrutura crescente ou decrescente, mas isso também pode depender dos dados apresentados (BENGIO, 2012). Nesse sentido, exemplifica-se as arquiteturas de redes

convolucionais (CNN) utilizadas para aprendizado profundo (e.g., *Inception*) as quais não adotam um padrão restrito. O uso do algoritmo de *Early Stopping* foi utilizado como critério de parada após uma tolerância ao erro (*patience*) de 15 épocas.

Tabela 9: Hiperparâmetros avaliados no algoritmo MLP

Hiperparâmetros	Quantidade ensaiada
No. de nós	(5, 6, 7)*, 8, 16, 24, 32, 48 e 64
No. de camadas ocultas	1, 2 e 3

(*) Foram avaliados somente na condição de uma única camada oculta.

3.3.2.2 SVR

O módulo do SVR foi utilizado por meio da classe ϵ -SVR baseado na biblioteca libsvm e contém os parâmetros C e ϵ . De acordo com os desenvolvedores do módulo (PEDREGOSA *et al.*, 2011):

- i. C: parâmetro de regularização que indica a penalidade aos erros e deve ser tanto menor conforme mais houver presença de ruídos nos dados; e
- ii. ϵ : especifica a região onde nenhuma penalidade é associada na função de perda do treinamento.

Tais hiperparâmetros foram testados no intervalo dos valores declarados na Tabela 10, organizada com 50 valores uniformemente espaçados dentro de tal faixa. Esses valores também foram otimizados com validação cruzada por meio do método de busca randômico (algoritmo *RandomSearch*) que proporcionasse um erro mínimo no lote de validação. Para mapeamento dos atributos de entrada foram avaliados os kernels por funções de base radial (RBF), polinomial e sigmoidal, comparando-se quando aplicado com todo conjunto de hiperparâmetros ensaiados acrescidos ainda do grau do polinômio e termo independente (coef_0). O parâmetro γ' da função RBF (Eq. 11) foi configurado para ser auto-escalonado, e varia de acordo com a quantidade de atributos e variância dos dados. Os demais argumentos da classe foram deixados no seu estado padrão, assim como o critério de parada estabelecido em uma tolerância de convergência de $1 \cdot 10^{-3}$ na aproximação da função objetivo.

Tabela 10: Hiperparâmetros avaliados no algoritmo SVR

Hiperparâmetros	Intervalo de valores
C	0,1 – 50
ϵ	0,005 – 1

3.3.2.3 XGB

Uma técnica de árvores conjuntas (*Ensemble*) com crescimentos sequenciais (*Boosting*) foi empregada para tarefa de regressão por meio da biblioteca XGBoost desenvolvida por CHEN e GUESTRIN (2016). A otimização dos hiperparâmetros também ocorreu por meio de validação cruzada. Nesse algoritmo foi experimentado uma varredura dos hiperparâmetros através da aproximação estocástica por evolução diferencial (DE) inspirado no trabalho com filtros de areia de GARCÍA NIETO *et al.* (2018). A rotina DE é apresentada por STORN e PRICE (1997) e foi implementada para validação dos hiperparâmetros com uso da biblioteca de FORTIN *et al.* (2012). Este conceito também é utilizado para otimização dos coeficientes β no modelo NLS pelo algoritmo do pacote DEoptim (ARDIA *et al.*, 2010). Essa rotina reduz o tempo necessário de busca dos melhores hiperparâmetros para os estimadores. Basicamente,

não se experimentam todas as combinações possíveis, mas sim, são evoluídas apenas as combinações que forneceram os melhores resultados.

De acordo com a documentação fornecida pelos desenvolvedores (CHEN e GUESTRIN, 2016), os hiperparâmetros XGB avaliados neste estudo interferem na natureza do modelo de acordo com os grupos maiores apresentados.

i. Estrutura da árvore

- **max_depth**: profundidade da árvore cujo acréscimo torna o modelo mais complexo e, consequentemente, mais propenso a *overfitting*;
- **min_child_weight**⁺: soma dos pesos das instâncias necessária para criação de um nó filho, e;
- **γ** ⁺: redução mínima na função objetivo para particionamento do nó.

ii. Regularizadores

- **λ** ⁺: estimula os pesos a serem pequenos, e é encontrado na literatura como *Ridge Regression* ou L_2 (HOERL e KENNARD, 1970).

iii. Randomização

- **subsample**: razão de subamostragem das instâncias de treino que ocorre a cada iteração, e;
- **colsample_bytree**: razão de subamostragem dos atributos na construção de cada árvore .

iv. Velocidade de aprendizado

- **η** : taxa de encolhimento estabelecida no passo para atualização dos pesos, e;
- **n_estimator**: número de árvores sequenciais produzidas, que são conciliadas com a taxa de encolhimento.

Os hiperparâmetros acompanhados de ⁺ indicam que quanto maior for o valor, mais conservador o modelo será. Tais hiperparâmetros foram testados na faixa dos valores declarados na Tabela 11 onde os pontos ensaiados uniformemente aos atributos **min_child_weight** e **λ** contém 10 valores dentro do intervalo, **max_depth**, **γ** , **subsample** e **η** com 5 e **colsample_bytree** com apenas 3 .

Tabela 11: Hiperparâmetros avaliados no algoritmo XGB

Hiperparâmetros	Intervalo de valores
max_depth	2 - 6
min_child_weight	0,1 - 20
γ	0,0 - 0,5
λ	0,1 - 1,0
subsample	0,5 - 1,0
colsample_bytree	0,8 - 1,0
η	0,1 - 1,0

Os valores limites do intervalo buscam a diminuição da complexidade do modelo impondo restrições e limitando a estrutura da árvore a fim de mais flexibilidade para os dados de teste. Adicionalmente, o uso de aleatoriedade força o treinamento a ser mais robusto aos ruídos inerentes. O número máximo de iterações é balanceado com a taxa de aprendizado e reduzido ao mínimo que satisfaça o modelo. Além disso, foi habilitado o critério de parada *Early Stopping* para uma tolerância máxima de 5 iterações que retornem incremento no erro de validação.

4 RESULTADOS E DISCUSSÕES

Em nenhuma das BDs (#1 e #2) verificou-se necessidade de técnicas de imputação por não haver dados faltantes. Não foram utilizados recursos de interação entre atributos (*feature engineering*) e os parâmetros dos modelos computacionais foram otimizados a partir dos dados brutos.

4.1 Bases de dados #1

4.1.1 Caracterização hidráulica

A caracterização hidráulica dos conectores é exibida graficamente com quatro imagens para cada classe de peças a fim de permitir comparações rápidas (Figuras 19 a 25). A imagem (1) apresenta a curva de valores de pressão diferencial (Δp) em função da vazão de ensaio (Q), sendo fornecida diretamente pelo transmissor da instrumentação. A imagem (2) ilustra a perda localizada de carga em função da velocidade média de escoamento (V) calculada sempre a jusante da conexão avaliada. A vazão de saída estimada em conectores do tipo Y ou do tipo T foi reduzida pela metade, pois a vazão na entrada da peça é dividida igualmente entre as duas saídas. Os valores de Δp foram corrigidos, subtraindo-se a perda distribuída de carga proporcionada pelo trecho do tubo de polietileno existente entre as tomadas de pressão e a peça avaliada. Variáveis de hf_L e V se correlacionam por uma regressão do tipo potência ($hf_L = aV^b$). A imagem (3) correlaciona a perda localizada de carga em função de carga cinética, sendo que o coeficiente angular da reta é uma estimativa de K_L . Por fim, na imagem (4) os valores de K_L foram plotados em função do Número de Reynolds.

4.1.1.1 Conectores iniciais (SC)

Na Figura 19 é apresentada a caracterização hidráulica dos conectores I_{SC} de códigos 37, 46, 57, 58, 59 e 186. O gráfico 3D dinâmico de tais conectores pode ser visualizado em <https://plot.ly/~wavila/61>. O gráfico dinâmico apresenta valores de Δp em função de Q e de características geométricas das peças. Tais características geométricas são baseadas na eq. de Borda-Bélanger (PORTO, 1998; AZEVEDO NETO, 2015) e consideram a razão dos diâmetros de entrada e do tubo $\left(1 - \frac{D_{in}}{D_L}\right)$. Os modelos 46 e 186 possuem amplitudes maiores entre as seções de entrada e saída e, consequentemente, assumem valores maiores de K_L . Maiores detalhes dos conectores supracitados encontram-se disponíveis em BOMBARDELLI (2018) e dados de terceiros considerados (ZITTERELL *et al.*, 2014; VILAÇA *et al.*, 2017). O gráfico 3D dinâmico contendo informação dos três autores pode ser visualizado em <https://plot.ly/~wavila/65>.

Na Figura 20 é apresentada a caracterização hidráulica dos conectores I_{VSC} de códigos 150, 152 e 182/183. Ensaios adicionais foram efetuados a fim de se obter o mesmo número de repetições dos demais casos. O gráfico 3D dinâmico pode ser visualizado em <https://plot.ly/~wavila/67>. Os ensaios atuais mostraram-se consistentes quando comparados aos antigos (BOMBARDELLI, 2018). Os ensaios anteriores resultaram valores um pouco acima de K_L , respectivamente aos modelos 150, 152 e 182/183 nas quais se obteve anteriormente 22,3, 11,0 e 23,0. Tal oscilação é esperada pois foram ensaiadas mais repetições do lote, considerando que há outras fontes de ruídos menores como erro de instrumentação e de instalação do componente. É interessante observar que os modelos 150 e 152 possuem características internas equivalentes, mas diferem dos diâmetros nominais especificados para o tubo de saída. O valor de K_L do modelo 150 é aproximadamente o dobro de K_L para o modelo 152 (Figura 20.3), sendo este efeito devido ao diâmetro do tubo instalado à jusante da conexão.

Na Figura 21 é apresentado a caracterização hidráulica dos conectores Y_{SC} de códigos 181, 208, 234 e 237. O gráfico 3D dinâmico pode ser visualizado em <https://plot.ly/~wavila/69>. O modelo 234 possui alargamento máximo entre o diâmetro de entrada e de saída, e apresenta o valor máximo de K_L nessa classe de conectores. Já os modelos 181 e 208, com saídas respectivas de 13 e 16 mm, apresentam

redução nas seções que resulta em valores de K_L reduzidos. O modelo 237 apresenta valores de 13 mm na entrada e saída.

Figura 19: Caracterização hidráulica dos conectores I_{SC} ensaiados por BOMBARDELLI (2018).

Figura 20: Caracterização hidráulica dos conectores Ivsc ensaiados.

Figura 21: Caracterização hidráulica dos conectores χ_{SC} ensaiados.

4.1.1.2 Conectores de união (UC)

Na Figura 22 é apresentado a caracterização hidráulica dos conectores I_{UC} de códigos 32, 81, 82 e 83. Dentre eles, o modelo 81 destinado para tubos de 13 mm oferece o K_L mais expressivo. O gráfico 3D dinâmico pode ser visualizado em <https://plot.ly/~wavila/59>. Maiores informações dos conectores se encontram disponíveis em BOMBARDELLI (2018).

Na Figura 23 é apresentado a caracterização hidráulica dos conectores I_{VUC} de códigos 151, 153 e 212/213/223. Novamente, foram executados ensaios adicionais a fim de se obter o mesmo número de repetições contidas nos demais casos. O gráfico 3D dinâmico pode ser visualizado em <https://plot.ly/~wavila/53>. Os modelos 151 e 153 também apresentam características internas equivalentes, mas são especificados para diferentes diâmetros de tubo. Como observado nos conectores I_{VSC} , tubos de diâmetros reduzidos proporcionam maiores velocidades, mas, mantendo a perda de carga, o coeficiente pode decair em até 55,7%. Os resultados dos presentes ensaios se mostraram consistentes quando comparado aos antigos (BOMBARDELLI, 2018).

Na Figura 24 é apresentado a caracterização hidráulica dos conectores Y_{UC} de códigos 180, 204 e 232. O gráfico 3D dinâmico pode ser visualizado em <https://plot.ly/~wavila/57>. Percebe-se a natureza de K_L reduzido pela característica de união para os modelos 180 e 204 respectivos aos diâmetros de 13 e 16 mm. Entretanto, o modelo 232 adiciona a característica de alargamento brusco nas seções, além da mudança na direção do escoamento propriamente dito. Em consequência, o K_L de 232 torna-se bastante expressivo para o grupo de união.

Na Figura 25 é apresentado a caracterização hidráulica dos conectores T_{UC} de códigos 109 e 164. O gráfico 3D dinâmico pode ser visualizado em <https://plot.ly/~wavila/55>. O modelo 109 (para tubos de 13 mm) apresentou a curva de hf_L mais íngreme quando comparado com o modelo 164 (de 16 mm).

Figura 22: Caracterização hidráulica dos conectores I_{UC} ensaiados por BOMBARDELLI (2018).

Figura 23: Caracterização hidráulica dos conectores Ivuc ensaiados.

Figura 24: Caracterização hidráulica dos conectores Y_{UC} ensaiados.

Figura 25: Caracterização hidráulica dos conectores T_{UC} ensaiados.

4.1.2 Estudo de caso

Perdas distribuídas e localizadas de carga devem ser rigorosamente detalhadas para um dimensionamento acurado nas subunidades (DEMIR *et al.*, 2007; FRIZZONE *et al.*, 2012; CELIK *et al.*, 2015; VILAÇA *et al.*, 2017; SOBENKO *et al.*, 2019). Neste tópico, realizaram-se simulações hidráulicas baseadas no procedimento trecho-a-trecho de uma linha lateral contendo conectores iniciais.

A perda total de carga na linha lateral (hf_T) é obtida somando-se os componentes de perda localizada provocada pelo conector inicial (hf_C), perdas localizadas devido aos emissores (hf_e) e perda distribuída ao longo da tubulação (hf). A perda distribuída de carga foi estimada utilizando a fórmula de Darcy-Weisbach com fator de atrito (f) calculado pela Eq. 18 (SWAMEE, 1993), sendo que a solução de f é válida para todos os regimes de escoamento. A perda localizada de carga proporcionada pela inserção de cada emissor na linha lateral foi estimada pela Eq. 26 (RETTORE NETO *et al.*, 2009a), válida apenas para emissores planos.

$$hf_e = 1,935 \left(\frac{A_g}{A_R} \right)^{1,190} \frac{V^2}{2g} \quad (26)$$

Em que, hf_e : perda localizada de carga provocada pela protrusão do emissor, (m); A_g : área de protrusão do emissor, (m^2), e; A_R : área de escoamento efetiva onde o emissor está inserido, (m^2).

A perda hf_C foi determinada com base nas classes de conectores apresentados por esta pesquisa. Nesse quesito, extraíram-se os modelos com K_L mais expressivos dentro de sua própria classe para os diâmetros de 13 e 16 mm. O critério utilizado para determinação do comprimento máximo (L_{max}) foi considerando $q_{var} \leq 10\%$ (i.e., $\frac{q_{max}-q_{min}}{q_{max}} \leq 10\%$). Consideremos no exemplo uma linha com declividade nula, $D_L = 13,7$ ou $16,3$ mm; $\epsilon' = 8 \mu m$. Emissores integrados não regulados com uma faixa de carga de pressão de operação de 10 -35 m, equação vazão-pressão $q = 1,039h^{0,54}$ e emissores uniformemente espaçados (Se) em 0,50 m. Adicionalmente, foi assumido que a carga de pressão no último emissor é de 11 m e o coeficiente de viscosidade cinemática da água é $1,007 \cdot 10^{-6} m^2 s^{-1}$. O processo permite a obtenção dos valores de pressão na entrada de cada um dos emissores e, quando acrescido das perdas de carga ao longo da linha, se obtém valores de L_{max} , hf e hf_e de acordo com os diâmetros. Assim, no caso de $D_L = 13,7$ mm tem-se $L_{max} = 61,0$ m, $hf = 1,87$ m e $hf_e = 0,78$ m. Para $D_L = 16,3$ mm tem-se $L_{max} = 81,0$ m, $hf = 1,73$ m e $hf_e = 1,06$ m.

A Tabela 12 resume essas simulações realizadas quantificando a percentagem de perdas localizadas provocadas por conectores iniciais instalados no início da linha.

Tabela 12: Resultados simulados indicando o peso dos conectores iniciais em linhas laterais.

D_L (mm)	Classe	Código	Resultados para L_{max_c}				hf_T (m)	$\frac{hf_C}{hf_{LL}}$ (%)	$\frac{hf_C}{hf_T}$ (%)	ΔL_{max} (%)
			L_{max_c} (m)	Q_0 (Lh^{-1})	hf_C (m)	hf_{LL} (m)				
13,7	I	57	59,0	469,09	0,229	2,715	2,944	8,5	7,8	3,3
	I _V	152	57,5	457,16	0,368	2,521	2,889	14,6	12,7	5,8
	Y	181	58,0	461,14	0,343	2,585	2,928	13,3	11,7	4,9
16,3	I	186	71,5	568,47	0,697	2,246	2,944	31,0	23,7	11,7
	I _V	182	72,5	576,42	0,635	2,338	2,974	27,2	21,4	10,5
	Y	234	64,5	512,82	0,891	1,670	2,562	53,4	34,8	20,4

Em que, D_L : diâmetro do tubo da linha lateral (mm); L_{max_c} : comprimento máximo considerando hf_C , (m); Q_0 : vazão de entrada na linha lateral, (Lh^{-1}); hf_C : perda localizada provocada pelo conector inicial (m); hf_{LL} : perda total de carga na lateral desconsiderando o conector inicial (m); hf_T : perda total de carga na lateral considerando o conector inicial (m); ΔL_{max} : porcentagem de redução

no comprimento da linha ocasionada por hf_C $\left[100 \left(1 - \frac{L_{maxC}}{L_{max}}\right)\right]$, sendo, L_{max} : comprimento máximo desprezando hf_C (i.e., 61 m para $D_L = 13,7$ mm e 81 m para $D_L = 16,3$ mm).

Observa-se na Tabela 12 que o decréscimo de L_{max} no tipo I é semelhante aos resultados obtidos por SOBENKO *et al.* (2019), os quais são superiores aos simulados por VILAÇA *et al.* (2017). Simulações indicaram uma redução máxima no comprimento de 20,4% no Y 234, que possui alargamento brusco na seção de escoamento. Em comparação, o Y 181 provocou menos impacto do que o Iv 152. Percebe-se ainda que o alargamento brusco proporcionou mais hf_C para I 186 do que para Iv 182, mesmo sem presença de registro.

O impacto do conector inicial pode representar menos de 10% das perdas de carga na linha lateral (hf_{LL}). Por exemplo, o I 57 mantém as seções de entrada e saída e é acoplado a um D_L reduzido (13,7 mm) que proporciona mais perdas por atrito na linha lateral. Por outro lado, como verificado no Y 234, os valores proporcionais de hf_C podem representar até mais da metade (53,4%) de hf_{LL} quando há alargamento brusco e mudança de direção no conector para acoplamento em tubos de diâmetros maiores (16,3 mm). Ou, ainda, a perda hf_C pode representar mais de um terço da perda total.

Mesmo assim, os projetos são usualmente dimensionados grosseiramente negligenciando-se hf_C , por se encontrarem desatualizados com os materiais disponíveis atualmente no mercado, quando não inexistentes (KOTOWSKI *et al.*, 2011; TSAKIRIS e TSAKIRIS, 2012). Evidentemente a caracterização hidráulica de todos componentes é importante para o correto dimensionamento de subunidades de microirrigação. Dito isso, os modelos computacionais otimizados permitem generalizar hf_C para outras conexões que se relacionem com o aprendizado desenvolvido, e oferecer um suporte satisfatório para estimativas de novos projetos.

4.1.3 Modelos otimizados

Na Figura 26 é apresentado uma matriz de correlação de Pearson quantificando como os pares de atributos da base completa se correlacionam linearmente. A análise exploratória de dados multivariados pode ajudar a entender e organizar os atributos em uma melhor relação funcional, pois tem como intuito descobrir se há um padrão mais evidente (BEHRENS, 1997; KOMOROWSKI *et al.*, 2016; GUZMÁN *et al.*, 2018). No estudo foram considerados os atributos individuais e em seus grupos adimensionais.

Figura 26: Matriz de correlação de Pearson dos atributos presenciados na BD #1 quantificando a interação entre os atributos individuais e em grupos adimensionais.

Baseado no critério de homogeneidade de BUCKINGHAM (1914), a relação funcional foi estabelecida tradicionalmente conforme a Eq. 27. Neste caso, apenas oito coeficientes ($\beta_1, \beta_2, \dots, \beta_8$) foram otimizados por meio da ferramenta NLS com uso do pacote DEoptim (ARDIA *et al.*, 2010) mantendo 2.000 iterações como solução do processo.

$$\frac{\Delta p}{\rho V^2} = \beta_1 \left(\frac{\rho V D_L}{\mu} \right)^{\beta_2} \left(\frac{D_{in}}{D_L} \right)^{\beta_3} \left(\frac{D_{out}}{D_L} \right)^{\beta_4} \left(\frac{D_G}{D_L} \right)^{\beta_5} \left(\frac{L_{in}}{D_L} \right)^{\beta_6} \left(\frac{L_{out}}{D_L} \right)^{\beta_7} \theta^{\beta_8} \quad (27)$$

Expressando Δp em termos de coluna d'água (i.e., $\Delta p = \rho g h_{f_L}$) e reagrupando os termos em função de todas variáveis, foi obtido a equação genérica correspondente ao modelo completo (Eq. 28) de h_{f_L} na passagem lateral para todos conectores apresentados.

$$h_{f_L} = 0,4872 \frac{V^{1,9540} \nu^{0,0460} D_L^{5,7376} D_{in}^{0,3496} L_{out}^{0,9506}}{D_{out}^{1,8296} D_G^{4,0956} L_{in}^{1,1586} \theta^{2,0673}} \quad (28)$$

Em que, h_{f_L} : perda localizada por conectores iniciais e de união, do tipo I com ou sem registros, do tipo T e do tipo Y, (m); V_L : velocidade média de escoamento, ($m s^{-1}$); ν : viscosidade cinemática da água, ($m^2 s^{-1}$); D_L : diâmetro interno da lateral, (m); D_{in} e D_{out} : respectivos diâmetros de entrada e saída, (m); D_G : diâmetro da garganta no caso de registros ou $D_G = D_{in}$ nos demais casos, (m); L_{in} e L_{out} : respectivos comprimentos de entrada e saída, (m), e; θ : ângulo formado pela entrada e saída (rad).

A Eq. 28 é válida sob as restrições adimensionais de valores: $2.753,1 \leq Re \leq 106.455,7$; $0,3503 \leq \frac{D_{in}}{D_L} \leq 0,9726$; $0,3503 \leq \frac{D_{out}}{D_L} \leq 0,8537$; $0,4147 \leq \frac{D_G}{D_L} \leq 0,9726$; $0,4859 \leq \frac{L_{in}}{D_L} \leq 3,1839$; $1,4576 \leq \frac{L_{out}}{D_L} \leq 6,3902$; $\frac{\pi}{2} \leq \theta \text{ (rad)} \leq \pi$.

Este modelo genérico (Eq. 28) quando aplicado ao conjunto de testes resulta em um RMSE de 0,8838 m, o que é consideravelmente alto quando comparado aos modelos dedicados. Já o erro relativo ($\delta = \frac{|y - \hat{y}|}{y}$) é de até 78,5% em 95% dos dados de teste. O atributo θ pode vir a ser unido ao grupo de Reynolds que considera as características do fluido (ρ e μ), operacionais (V) e dimensão do tubo de saída (D_L). Além disso, o número de Reynolds não apresenta uma correlação relativamente alta (0,23) com θ , e

talvez um ajuste não-linear possa maximizar tal interação. Se for incluído mais coeficientes β no modelo, como aplicando a exponenciação do ângulo em Reynolds (e.g. Re^{β_9}), obtém-se um decréscimo do RMSE para 0,8205 m. No entanto, o δ obtido em 95% dos dados de teste aumentaria para até 94,7% indicando que um aumento na complexidade do modelo reduziria a capacidade de generalização. Sobretudo, um bom modelo, além de se ajustar bem aos dados, deve também ser parcimonioso (BATES *et al.*, 2015), ou seja, o modelo deve ser complexo apenas o suficiente para descrever o problema.

Desenvolveram-se modelos NLS dedicados (Eqs. 29 a 35) para cada uma das classes seguindo a regressão do tipo potência simples (Eq. 24), mantendo o padrão de unidades de entrada usado na Eq. 28, mas com valores limitados às classes e, consequentemente, mais restritos. São modelos para os conectores iniciais: I_{SC} (Eq. 29), I_{VSC} (Eq. 30) e Y_{SC} (Eq. 31), e; conectores de união: I_{UC} (Eq. 32), I_{VUC} (Eq. 33), Y_{UC} (Eq. 34) e T_{UC} (Eq. 35).

$$I_{SC} \rightarrow hf_L = 0,0489 \frac{V^{1,9968} \nu^{0,0032} L_c^{0,3030} D_L^{3,7395}}{D_{in}^{3,8611} D_{out}^{0,1845}} \quad (29)$$

$$I_{VSC} \rightarrow hf_L = 0,0863 \frac{V^{1,9919} \nu^{0,0081} L_{in}^{0,8289} D_L^{3,8448}}{D_{in}^{3,7489} D_{out}^{0,3261} D_G^{0,1953} L_{out}^{0,4115}} \quad (30)$$

$$Y_{SC} \rightarrow hf_L = 0,0504 \frac{V^{2,0286} L_{out}^{0,9473} D_L^{4,7000}}{\nu^{0,0286} D_{in}^{1,2089} D_{out}^{1,3201} L_{in}^{3,0895}} \quad (31)$$

$$I_{UC} \rightarrow hf_L = 0,0157 \frac{V^{1,9946} D_L^{4,5710} L_c^{0,4236} \nu^{0,0055}}{D_i^5} \quad (32)$$

$$I_{VUC} \rightarrow hf_L = 0,0118 \frac{V^{2,0134} D_L^{4,2341} L_c^{0,9641}}{\nu^{0,0134} D_i^{3,5032} D_G^{1,6816}} \quad (33)$$

$$Y_{UC} \rightarrow hf_L = 0,2036 \frac{V^{1,9807} \nu^{0,0193} D_L^{1,6491} D_{out}^{4,9933} L_{out}^{0,3091}}{D_{in}^{4,9885} L_{in}^{1,9823}} \quad (34)$$

$$T_{UC} \rightarrow hf_L = 0,0034 \frac{\nu^{0,1076} V^{1,8924} D_i^{0,5441} L_i^5}{D_L^{5,6517}} \quad (35)$$

Nesses, D_i : diâmetro interno médio, $\frac{(D_{in}+D_{out})}{2}$, (m); L_i : comprimento médio dos trechos, $\frac{(L_{in}+L_{out})}{2}$, (m), e; L_c : comprimento total, $L_{in} + L_{out}$, (m).

Estes modelos dedicados assumem erros consideravelmente menores, com RMSE variando de 0,123 m em conectores I_{UC} até o máximo de 0,301 m em conectores I_{SC} . O Apêndice IV contém um quadro sucinto dos conectores e códigos com seus modelos empíricos obtidos.

A Tabela 13 informa as restrições condicionadas aos valores mínimos e máximos de entrada nos modelos NLS otimizados e dedicados (Eqs. 29 a 35).

Tabela 13: Limitações dos modelos NLS dedicados às classes com seus valores mínimo e máximo de entrada

Tipo	Eq.		V (m s ⁻¹)	ρ (kg m ⁻³)	μ (Pa s) 10 ⁻⁴	D _{in} (mm)	D _{out} (mm)	D _G (mm)	L _{in} (mm)	L _{out} (mm)	θ (rad)	D _L (mm)
I _{SC}	30	X _{min}	0,148	993,4	8,380	2,32	2,32	-	5,37	16,11	3,142	4,05
		X _{max}	5,586	995,7	9,768	16,05	16,74	-	22,93	43,28	3,142	26,92
Iv _{SC}	31	X _{min}	0,315	996,3	8,362	9,46	11,51	7,55	33,44	33,18	3,142	13,70
		X _{max}	3,520	997,6	9,441	9,51	11,61	7,58	33,57	43,14	3,142	16,39
Y _{SC}	32	X _{min}	0,861	996,1	8,235	9,32	9,30	-	17,70	45,88	2,487	13,70
		X _{max}	5,010	996,9	8,825	15,94	11,53	-	20,77	47,93	2,487	16,39
I _{UC}	33	X _{min}	0,670	996,3	8,409	9,43	9,43	-	31,73	31,73	3,142	13,70
		X _{max}	5,586	997,5	9,339	11,95	11,95	-	39,99	39,99	3,142	16,39
Iv _{UC}	34	X _{min}	0,312	995,7	8,037	11,48	11,48	7,65	39,81	39,81	3,142	13,70
		X _{max}	3,491	997,3	9,093	11,58	11,58	7,98	50,28	50,28	3,142	16,39
Y _{UC}	35	X _{min}	0,748	995,6	7,955	9,40	9,35	-	30,33	45,37	2,487	13,70
		X _{max}	6,270	996,6	8,627	11,51	11,56	-	32,56	49,83	2,487	16,39
T _{UC}	36	X _{min}	0,839	995,7	8,041	8,77	8,78	-	42,87	42,27	1,571	13,70
		X _{max}	5,082	996,5	8,550	11,55	11,55	-	44,40	42,93	1,571	16,39

Na Figura 27 é exibido o desempenho comparativo dos erros obtidos por meio do modelo genérico ($\blacktriangle$) e dos modelos dedicados ($\bullet$) para cada um dos tipos de conectores. Evidencia-se que o modelo genérico assume erros superiores nos modelos para conectores iniciais do tipo I_{SC}, que possui ruídos inerentes dos ensaios de diferentes autores, sucedido pelo tipo Y_{SC}. Destaca-se que o tipo T também confere uma mudança na direção ($\alpha \neq \pi \rightarrow \alpha = \frac{\pi}{2}$ rad) mas não concede um erro tão expressivo. Este padrão de erro se mantém mesmo quando se utilizam de modelos genéricos mais complexos. Nos modelos dedicados o erro foi máximo na classe de I_{SC}, sendo que a Figura 27 acompanha sua ordenação em forma decrescente. A amplitude do erro entre os modelos de cada tipo é mínima em I_{UC} (a = 0,070 m), seguida por T_{UC} (b = 0,306 m), Iv_{SC} (c = 0,393 m), Iv_{UC} (d = 0,496 m), Y_{UC} (e = 0,860 m), I_{SC} (f = 0,861 m) e, no máximo, Y_{SC} (g = 0,903 m).

Figura 27: Erros no conjunto de testes obtidos de acordo com classes de conectores e modelos NLS do tipo: ($\blacktriangle$) genérico, e; ($\bullet$) dedicado.

Modelos dedicados por algoritmos computacionais também foram validados em ensaios preliminares e superaram a acurácia dos modelos matemáticos dedicados. Contudo, o desafio deste estudo se pauta em propor o aprendizado mais completo possível. Nesse sentido, o critério de comparação será acima de modelos genéricos e, portanto, o modelo genérico simples (Eq. 29) foi empregado para comparação detalhada com os demais modelos por aprendizado de máquina.

Na Figura 28 é informado a variação do erro na rede MLP em relação às camadas e nós envolvidos. De modo geral, uma única camada apresentou os menores erros. Vários autores afirmam que uma única camada é suficiente para aproximar uniformemente qualquer função suave e contínua (CYBENKO, 1992; HORNIK *et al.*, 1989; GUNTHER e FRITSCH, 2010). Percebe-se que o incremento de camadas não favoreceu a capacidade de generalização aos dados não-observados de teste, tornando o modelo mais complexo e com menos flexibilidade. Dito isso, a arquitetura adotada na rede MLP ficou composta com apenas uma camada oculta contendo 32 nós que atingiu um RMSE de 0,1990 m.

Figura 28: Erro mínimo observado variando as interconexões (a); e rede MLP adotada para base genérica de conectores (b), em que uma camada oculta com 32 nós e um bias se sobressaiu na simulação.

No módulo SVR, a função ϕ do tipo RBF demonstrou melhor ajuste aos dados de teste atingindo um RMSE de apenas 0,1867 m, sobressaindo também na escolha de outros autores (GARCÍA NIETO *et al.*, 2016; GUZMÁN *et al.*, 2018; FAN *et al.*, 2018a). Houve incremento do RMSE utilizando de funções polinomiais (0,4468 m). Funções sigmoidais foram completamente inadequadas. Adotou-se uma folga na regularização de C estabelecendo um custo de 40,43 por meio da otimização aleatória dos hiperparâmetros, apontando um modelo mais tolerante do que quando comparado com o padrão da biblioteca. Balanceando o modelo, o tubo ϵ é mais fino e indica que mais pontos sofrem penalidades na construção dos hiperelipsóides (PEDREGOSA *et al.*, 2011).

Na Figura 29 é apresentado uma comparação do modelo otimizado (Modelo 1*) com outros

modelos configurados ao acaso para uma simulação do balanço bias-variância obtido sobre amostragem aleatória de 50 pontos extraídos do conjunto de testes. Os valores do atributo meta (Δp) foram escalonados para o intervalo de $[-1, 1]$. Observa-se como o Modelo 3 apresentou variância excessiva e os demais modelos hipotéticos (2 e 4) ficaram altamente enviesados, enquanto o otimizado Modelo 1* demonstrou mais equilíbrio e proximidade aos pontos parciais não-observados.

Figura 29: Modelos SVR com hiperparâmetros randômicos para simulação do balanço bias-variância, cujo Modelo 1* corresponde ao modelo otimizado adotado.

No modelo XGB, a otimização por evolução diferencial (DE) foi acompanhada com a simulação dos hiperparâmetros utilizando do pacote Caret (KUNH, 2008) na linguagem R. Na Figura 30 é fornecido a progressão do erro na validação cruzada (CV) diante de hiperparâmetros sequencialmente simulados na ordem de (a) complexidade da árvore e taxas de aprendizagem; (b) critério de regularização no particionamento do nó, e; (c) aleatorização dos dados. Houve redução contínua do erro em todos os casos de acordo com o incremento de iterações, e pouco impacto em (a) para uma profundidade máxima de 5 níveis após 120 árvores sequenciais quando $\eta = 0,3$ (padrão). Uma vez estabelecido isso, efetuaram-se sequencialmente as simulações para visualização do impacto dos parâmetros de regularização(b) e de aleatorização (c).

Os hiperparâmetros do XGB obtidos na otimização DE se mostraram consistentes com os simulados, e foram adotados para o treinamento do modelo final. A fim de se obter um modelo ainda mais simples foi incluído penalidade λ (1,20) na função objetivo, assim como o piso de γ (0,05) para que um novo nó seja criado.

Figura 30: Hiperparâmetros do XGB simulados paralelamente, iniciado na ordem de, (a) quatro valores de encolhimento (η) para cinco níveis de profundidade da árvore; (b) critério para criação de um nó hierárquico acima do somatório mínimos dos pesos, e; (c) aleatorização da amostragem fracionada de instâncias (0,5, 0,75, 1) sob frações de atributos na árvore (0,4, 0,6, 0,8 e 1,0)

Resumidamente, na Tabela 14 são informados os valores otimizados dos hiperparâmetros ajustados em cada uma das técnicas ensaiadas para a BD #1.

Tabela 14: Hiperparâmetros otimizados ao modelo genérico de conectores

Modelo	Hiperparâmetro	Valor otimizado
MLP	Interconexões	10-32-1 (32 nós + 1 bias)
SVR	C	40,43
	ϵ	0,0525
	φ	RBF
XGB	max_depth	5
	min_child_weight	5,55
	γ	0,05
	λ	1,20
	subsample	0,65
	colsample_bytree	1,00
	η	0,30

Na Figura 31 é apresentado o custo de treinamento do modelo genérico quando comparado com os modelos dedicados às classes. Na categoria dos modelos genéricos (Fig. 31a, em cinza), observa-se que o MLP atingiu um erro próximo ao SVR em aproximadamente 5 minutos. Inclusive, tal MLP sobressaiu os próprios modelos dedicados para I_{SC} , I_{VSC} e I_{VUC} , demonstrando que o reconhecimento do padrão é fortalecido com alimentação massiva dos dados por esta ferramenta. Verifica-se que o tempo de execução do SVR foi condizente com os resultados de FAN *et al.* (2018b) e corrobora com o que os desenvolvedores PEDREGOSA *et al.* (2011) recomendam sobre o uso. A Figura 31b aproxima a escala ao tempo demandado nos modelos dedicados. Assim, evidencia-se o incremento da acurácia dos modelos computacionais comparados ao NLS. Percebe-se que mesmo forçando o número de ciclos no algoritmo DE - tornando-o mais refinado e, conseqüentemente, mais custoso - os modelos NLS retornaram erros maiores que os demais modelos. Sobretudo, o custo é computado apenas sobre o tempo de execução dos cálculos iterativos com um critério de parada fixo, e não considera a tentativa e erro de múltiplos arranjos que possam anteceder tal processo.

Na categoria dos modelos dedicados (Fig. 31b, em colorido), as bases de dados são considera-

velmente menores. Assim, os modelos SVR demandaram um tempo bem mais reduzido e até atingiram erros inferiores ao MLP. Nessa categoria, complementando a Figura 27, o modelo NLS do tipo I_{SC} retornou erro e custo máximo, enquanto os modelos XGB apresentaram majoritariamente erros menores em menos de meio minuto.

Figura 31: Custo do tempo de execução de acordo com os modelos computacionais e matemático; sendo (a) considerando o tempo total utilizado (hh:mm:ss) para o treinamento completo (erro em escala logarítmica), e; (b) restringindo a escala ao tempo demandado (mm:ss) pela maioria dos modelos (erro em escala linearizada)

4.1.4 Indicadores de erro

A Figura 32 apresenta o desvio entre valores observados e estimados por modelos genéricos matemático (NLS) e computacionais (MLP, SVR e XGB) acompanhado dos respectivos histogramas de erros obtidos.

A imagem do modelo NLS apresenta-se como um complemento da informação contida na Figura 27. Neste caso, foi destacado cada uma das classes específicas nas quais verifica-se uma alta dispersão proporcionada por conectores do tipo I_{SC} e a tendência divergente nos tipos Y_{SC} e Y_{UC} . Os demais conectores se mostraram menos irregulares com a reta identidade. Observa-se que o modelo NLS apresenta uma variância relativamente alta com uma tendência de que as predições sejam subestimadas.

Os erros observados nos modelos SVR e MLP encontram-se bem adensados na reta identidade e compartilham de distribuições de erros semelhantes. O modelo SVR apresenta o pico suavemente acima do erro comparado ao MLP. O modelo XGB não apresentou a consistência uniforme de dispersão dos pontos (do tipo leque) como visualizado nos modelos MLP e SVR, além de que há mais variância nos erros e uma inclinação para predições subestimadas. Nota-se ainda que não há valores preditos para o XGB acima de aproximadamente 10 m, dado que a distribuição dos dados da BD #1 possui pouca representatividade acima de tais condições (Apêndice II). Nesse caso, os valores observados de hf_L acima de 10 m foram estimados grosseiramente junto ao intervalo de 6 a 8 m.

Figura 32: Valores observados e estimados de perda localizada de carga (a) por modelos genéricos (matemáticos e computacionais) e histograma de erros (b). Em que, em (a), linha cinza: reta identidade, e; linha preta pontilhada: regressão linear com coeficiente de determinação.

Na Figura 33 é informada a curva característica de erro da regressão (do acrônimo REC). Neste caso, contabilizam-se os dados de teste por sua frequência acumulada e esses são correlacionados aos índices de erro relativo (δ) de todos modelos testados. Em 95% das estimativas utilizando o conjunto de dados de teste (aproximadamente 64.427 instâncias), os erros relativos foram de até: SVR: 14,6%; MLP: 16,0%; XGB: 24,9% e NLS: 78,2%. Se fossem utilizadas apenas as médias amostrais de cada condição da válvula proporcional sob abertura crescente, o δ_{95} atingiria erros superiores aos dados acumulados na ordem supracitada de 20,5%; 24,4%; 29,9%; 88,1%, sugerindo que erros normalmente distribuídos não comprometem tanto quanto a alimentação de dados no aprendizado.

Figura 33: Erro relativo (δ) dos modelos avaliados da BD #1 em domínio da frequência acumulada do conjunto de teste, com demonstração da porcentagem de dados para a condição de erro menor ou igual a 5% e 10% em 95% dos dados (δ_{95}).

Percebendo que δ varia de acordo com a velocidade média de escoamento, compararam-se os erros relativos médios ($\bar{\delta}$) dos modelos avaliados em 8 intervalos de velocidades (Figura 34). O modelo NLS apresentou os valores mais altos de $\bar{\delta}$, na faixa de velocidades entre $(2,87, 3,55] \text{ m s}^{-1}$ com um erro relativo de 38,5%, seguido pela velocidade entre $(0,152, 0,835] \text{ m s}^{-1}$ com 32,2%. Tal faixa também apresentou os maiores $\bar{\delta}$ nos modelos computacionais, respectivos aos modelos MLP, SVR e XGB de 10,2%, 9,38% e 12,22%. Em tais modelos observa-se uma tendência grosseira do erro médio diminuir de acordo com o aumento da velocidade, mas isto é um comportamento aleatório dependente da acomodação dos ruídos possivelmente pela acurácia do transmissor em tais condições. Assim, nos intervalos extremos de velocidade máxima observa-se um pequeno acréscimo de $\bar{\delta}$ quando comparado aos seus intervalos antecessores. Dito isto, na faixa de velocidades de escoamento $(4,23, 4,90] \text{ m s}^{-1}$, o modelo NLS destaca-se com $\bar{\delta}$ de 4,65%, abaixo dos modelos MLP e SVR que respectivamente apresentaram 5,41% e 5,28%, enquanto o XGB obteve o mínimo com 3,70%.

Figura 34: Erro relativo médio da BD #1 obtido em intervalos da velocidade média de escoamento (V).

Na Figura 35 é ordenada a importância dos atributos para divisão dos nós no XGB em percentuais de ganho (i.e., o incremento na acurácia fornecida quando ele é considerado para os ramos da árvore). Essa classificação está de acordo com a relação da Eq. 1 e Fig. 26 indicando que hf_L está relacionada com a velocidade e, conseqüentemente, com as condições de operação do sistema. O coeficiente de proporcionalidade K_L pode ser descrito sobretudo pelas características geométricas considerando um regime turbulento. Neste caso, considerando todas as bases de dados, o componente D_G assumiu o peso máximo entre tais características, tendo uma importância similar a V .

Destaca-se que, na medida em que as árvores são impulsionadas, o erro decai com a minimização dos resíduos da função objetivo. Porém, a importância de V também decresce, enquanto D_G acaba assumindo a liderança como atributo mais importante. Vale considerar que o atributo D_G assume o peso de D_{in} nos conectores sem registros. O atributo L_{in} assume uma importância relativamente alta pois pode ajudar na categorização dos conectores em seus respectivos grupos (conectores de união e iniciais) na árvore de decisão.

Em tais condições de ensaio as informações de propriedades do fluido (ρ e μ) se mostraram com importância relativamente baixa para o modelo, mas cabe frisar que a BD utilizou de apenas um único fluido sob uma determinada faixa de temperatura e não expressa as demais situações.

Figura 35: Pontuação de relevância dos atributos da BD #1 para divisão dos nós pelo algoritmo XGB.

4.1.5 Desenvolvimento WEB

Uma aplicação WEB foi desenvolvida como ferramenta para simulações de perda localizada de carga como uma função das características geométricas, operacionais e propriedades do fluido. A aplicação está disponível no endereço <http://mlosses.pythonanywhere.com/>.

A interface da página WEB foi programada utilizando-se de linguagens HTML, CSS e JavaScript, enquanto os modelos computacionais são carregados em Python com uso da interface Flask. O usuário seleciona o grupo e classe dos conectores e, em seguida, preenche um formulário descrevendo os valores de entrada. Permite-se, assim, que os valores de hf_L sejam estimados aos modelos baseados em regressões não-lineares tradicionais (NLS) e computacionais (MLP, SVR e XGB). Curvas de perda de carga versus velocidade são construídas e suas correspondentes equações do tipo potência ($hf_L = aV^b$) são retornadas, acompanhadas do coeficiente de determinação.

Neste tópico, consideremos tanto os modelos dedicados (NLS) quanto o modelo genérico (NLS*). Caso os valores informados pelo usuário extrapolem os valores limites utilizados no ajuste do modelo NLS, tal curva é ocultada do gráfico. Neste caso é indicado os atributos que excederam o conjunto dedicado e informa-se o resultado obtido pelo modelo NLS*. Se ainda os valores de entrada extrapolarem os valores da base completa utilizada, a operação é cancelada e o usuário é informado dos atributos que extrapolam os limites de validade dos modelos de predição. Essa rotina de condição permite que o usuário observe a limitação dos intervalos dedicados, mas também permite comparar a estimativa dos modelos genéricos quando encaixados no limite do modelo dedicado.

Na Figura 36 é apresentado as curvas construídas pelo aplicativo WEB de perda localizada em função da velocidade de escoamento obtidas por simulações hipotéticas com instâncias aleatórias de teste. Os valores adotados se encontram dentro dos limites de cada classe e a curva NLS é fornecida, a fim de guiar os modelos genéricos com o ajuste específico de erro reduzido.

Observa-se no tipo Y_{UC} que o modelo SVR acompanhou a curva NLS*, enquanto o modelo XGB se junta a eles em velocidades superiores a 2 m s^{-1} . O modelo MLP acompanha o NLS, mas acaba subestimando-o em velocidades superiores. Ocorre que no tipo Y_{SC} os resultados obtidos por modelos computacionais se aproximam mais da curva por NLS, enquanto o NLS* encontra-se isolado.

Já nos tipos I_{UC} e I_{SC} aproximadamente todos modelos acompanharam a mesma tendência. O tipo I_{SC} contém dados de múltiplos autores e é mais favorável aos ruídos, porém, neste caso, os valores de entrada utilizados favoreceram todos os modelos.

Nos tipos de conectores com registros (Iv), o MLP acompanhou o NLS, enquanto o SVR não acompanhou o grupo de conectores de união. No tipo T_{UC} , os modelos computacionais se aproximaram mais do NLS, sendo que o XGB acaba o superestimando e os demais o subestimam. Nesse quesito, o MLP é o mais aproximado enquanto o NLS* é o mais afastado.

Figura 36: Representação hipotética das curvas hf_L versus V pelo aplicativo WEB a partir de dados de teste condicionados no intervalo dos modelos limitados. Em que, NLS representa o modelo dedicado a cada tipo e NLS (*) o modelo genérico.

Na Figura 36 é revelado o comportamento insatisfatório das curvas estimadas pelo modelo XGB. Para um dado conjunto de características geométricas, a curva de perda localizada de carga em função de velocidade de escoamento sempre deve seguir uma função potencial, sendo que as estimativas obtidas pelo XGB não seguem esse comportamento. Adicionalmente, as árvores não extrapolam bem os dados além do treino, o que é evidenciado quando hf_L se aproxima de 10 m.

É reconhecido ainda que os algoritmos clássicos de SVM são baseados na premissa de que todos atributos alimentados no treino possuem contribuição idêntica para a descrição da saída (PEDREGOSA *et al.*, 2011). No entanto, tal premissa nem sempre é verdade em casos reais e pode exigir o desenvolvimento de modelos híbridos (CHEN e HAO, 2017), como proposto no trabalho com filtros de areia de GARCÍA NIETO *et al.* (2016).

Por sua vez, o modelo MLP considerou que hf_L possui uma regressão bem ajustada com os modelos tradicionais e as previsões se mostraram mais próximas dos modelos dedicados (NLS) quando os dados de entrada se encontram dentro de seus limites restritos.

4.2 Base de dados #2

4.2.1 Modelos otimizados

Neste caso, os modelos de predição são interessantes para que projetistas e fabricantes simulem o impacto de mudanças geométricas nos labirintos na vazão dos emissores. De modo análogo para a BD #1, a Figura 37 exibe a quantificação das relações lineares entre os pares de atributos envolvidos na base de dados. Basicamente o atributo-meta de vazão (q) está diretamente relacionado com a carga de pressão de operação (h), que por sua vez é totalmente independente das características geométricas.

Figura 37: Matriz de correlação de Pearson dos atributos presenciados na BD #2 quantificando a interação entre os atributos individuais. Em que, (*) indica valores $< 0,001$.

Essas interações estão presentes na aplicação do modelo NLS construído pelos autores LAVANHOLI *et al.* (2020) como foi apresentada anteriormente (Eq. 6).

O algoritmo MLP foi ensaiado com os hiperparâmetros mencionados na Tabela 9. Observou-se, contudo, que o desafio do treinamento acima de bases pequenas confere ainda mais cautela no aumento do número de conexões (Figura 38). Nessa condição o uso de apenas uma camada torna-se ainda mais eficiente quando aplicado aos dados não observados de teste. Evidencia-se que a capacidade de generalização é consideravelmente reduzida com o aumento da complexidade, visto o acréscimo do erro quando se incluíram mais camadas na rede. Por isso, os valores mínimos da Tabela 9 foram ainda mais reduzidos, a fim de certificar a quantia de 6 neurônios em apenas uma camada oculta contendo o RMSE mínimo ($0,2652 \text{ Lh}^{-1}$) ensaiado. O erro mais próximo imediatamente encontrado foi observado com 64 nós e, ainda assim, assume-se imediatamente superior ($0,2653 \text{ Lh}^{-1}$).

Figura 38: Erro mínimo observado variando as interconexões (a); e rede MLP adotada para base de emissores (b), em que uma camada oculta com 6 nós e um bias se sobressaiu na simulação.

Novamente, no módulo SVR, a função ϕ do tipo RBF apresentou um mapeamento mais acurado com RMSE mínimo de $0,2216 \text{ Lh}^{-1}$ aos dados de teste, seguido pelas funções polinomiais ($0,6031 \text{ Lh}^{-1}$) e sigmóide ($0,7420 \text{ Lh}^{-1}$). Ofereceu-se ao modelo otimizado um C suavemente reduzido ao caso da BD #1 e um tubo ϵ ainda mais estreito.

Na Figura 39 é apresentado uma comparação do modelo otimizado (em verde) com outros modelos aleatoriamente configurados para simulação do balanço bias-variância obtido em todo conjunto reservado para teste (32 pontos). Os valores do atributo meta (q) se encontram escalonados no intervalo de $[-1,1]$. Observa-se que todos os modelos aleatórios se apresentaram mais enviesados e com menos variância em torno da média, enquanto o modelo otimizado apresentou-se mais aproximado de todos os pontos não observados.

Figura 39: Modelos SVR com hiperparâmetros aleatórios para simulação do balanço bias-variância com dados de teste da BD #2, cujo Modelo 1* corresponde ao modelo otimizado adotado.

Analogamente, validou-se a otimização DE simulando condições cruzadas dos hiperparâmetros no impulso de árvores (Figura 40). O modelo foi otimizado com apenas 80 iterações para minimização do resíduo sob uma taxa η de 0,3. Baseado nisto, o algoritmo evolucionário convergiu para valores semelhantes considerando a soma mínima dos pesos de instâncias para 2,31 e um fracionamento aleatório de 75% das instâncias com aleatorização de 80% dos atributos em cada árvore. Os parâmetros regularizadores foram reduzidos ($\lambda = 0,80$) ou se mantiveram nulos ($\gamma = 0$)

Figura 40: Hiperparâmetros do XGB simulados paralelamente, iniciado na ordem de, (a) quatro valores de encolhimento (η) para cinco níveis de profundidade da árvore; (b) critério para criação de um nó hierárquico acima do somatório mínimos dos pesos, e; (c) aleatorização da amostragem fracionada de instâncias (0,5, 0,75, 1) sob frações de atributos na árvore (0,4, 0,6, 0,8 e 1).

Resumidamente, na Tabela 15 é informado os valores otimizados para os hiperparâmetros configurados em cada uma das técnicas ensaiadas para a BD #2.

Um fato esperado da BD #2 é que o tempo de execução dos treinamentos é ínfimo quando comparado com a BD #1 para todas as técnicas e, portanto, não se assume relevante o suficiente para comparações. Definitivamente o custo do tempo não é o empecilho encontrado em bases reduzidas, onde o modelo MLP foi o que dispendeu mais tempo e demandou 1 minuto e 20 segundos. Justamente o problema de bases pequenas acaba sendo a falta de informação para o pleno aprendizado do modelo.

Tabela 15: Hiperparâmetros otimizados ao modelo genérico de emissores

Modelo	Hiperparâmetro	Valor otimizado
MLP	Interconexões	6-6-1 (6 nós + 1 bias)
SVR	C	34,52
	ϵ	0,025
	φ	RBF
XGB	max_depth	3
	min_child_weight	2,31
	γ	0,00
	λ	0,80
	subsample	0,75
	colsample_bytree	0,80
	η	0,30

4.2.2 Indicadores de erro

Observa-se que a BD #2 contém um número de instâncias bem reduzido e, assim, o conjunto de testes é limitado estatisticamente e acaba ocasionando maiores divergências entre os indicadores de treino e teste dos estimadores. Nesta condição, verifica-se que o modelo XGB sem regularizadores apresentou o limiar de igualdade, enquanto os demais modelos adotaram maiores restrições no ajuste de treino.

Na Figura 42 é apresentado o desvio entre valores observados e estimados da BD #2 com as técnicas NLS, MLP, SVR e XGB.

Em tais técnicas observou-se um ajuste linear bem adensado com a reta identidade, mas o histograma de erros acusa uma variância mais acentuada no modelo NLS. No modelo MLP prevaleceu uma tendência de superestimativa dos dados preditos quando comparados aos dados observados. Já o modelo XGB foi o que apresentou os erros mais centrados em torno da média. De modo geral, todos modelos foram bem sucedidos e com pouca diferença entre si. Porém, cabe ressaltar que nessa base o suporte do conjunto de testes é limitado.

Figura 41: Valores observados e estimados de vazão (a) e histograma de erros (b). Em que, em (a), linha cinza: reta identidade, e; linha preta pontilhada: regressão linear com coeficiente de determinação.

Na Figura 42 é analisado o gráfico REC para a BD #2 utilizando os dados de teste para os modelos desenvolvidos. Todos os modelos computacionais apresentaram menores erros relativos do que o modelo NLS. Os valores de δ em 95% das estimativas para os dados de teste foram: XGB: 4,4%, MLP: 4,6%, SVR: 6,8% e NLS: 7,6%. Os modelos por MLP e XGB apresentaram erros menores do que 5% em 95% dos dados de teste. Com tais dados foi obtido δ abaixo de 10% por todos os modelos avaliados. Nessa análise, o modelo XGB apresentou o melhor desempenho.

Figura 42: Erro relativo (δ) dos modelos avaliados da BD #2 em domínio da frequência acumulada do conjunto de teste, com demonstração da porcentagem de dados para a condição de erro menor ou igual a 5% e 10% e erro máximo em 95% dos dados (δ_{95})

Na Figura 43 são apresentados os valores de carga de pressão (h) e erros relativos médios ($\bar{\delta}$) correspondentes aos modelos ensaiados. Nota-se que o $\bar{\delta}$ máximo ocorreu na menor carga de pressão em todas as técnicas, que é ainda mais acentuada no modelo NLS (5,56%) e seguido dos modelos SVR (4,19%), MLP (2,44%) e XGB (1,57%) respectivamente. Evidencia-se também que usualmente o modelo NLS apresentou $\bar{\delta}$ maiores. Contudo, tal modelo destacou-se com um $\bar{\delta}$ abaixo dos demais em duas condições operacionais de carga de pressão de 25 e 35 m com erros respectivos de 0,39 e 0,55%.

Nos modelos computacionais, o MLP apresentou erros maiores, mas nota-se que há pouca variação entre todos intervalos. O MLP e o SVR destacaram-se na pressão de 15 m com erro médio de 1,27 e 0,47%, respectivamente, sendo o último o erro presenciado pelo XGB na carga de pressão de 30 m.

Figura 43: Erro relativo médio da BD #2 obtido em intervalos da pressão de operação (h)

Na Figura 44 é ordenada a importância dos atributos para divisão dos nós no XGB em percentuais de ganho. Essa classificação torna claro que a pressão de operação é o atributo-chave para estimativa da vazão em emissores não-regulados, conforme esperado e expresso pela relação vazão-pressão de emissores $q = kh^x$ (FRIZZONE *et al.*, 2012). Nos demais atributos preditores têm-se os geométricos, onde destacou-se a profundidade do canal (Z) seguido pelo ângulo dos defletores (α), que, segundo Li *et al.* (2006), é um dos parâmetros construtivos que mais afetam o coeficiente de perda localizada em labirintos trapezoidais. Conhecendo o fenômeno físico, evidencia-se que a característica geométrica mais relevante para estimativas de vazão é a seção de escoamento. Como essa variável é resultado do produto entre profundidade (Z) e largura do labirinto (W), a Figura 44 não contém tal informação. Como o modelo foi treinado apenas a partir de atributos individuais, não é possível quantificar a importância da seção de escoamento nas estimativas de vazão. Neste caso, os demais atributos individuais (H, W e L) apenas contribuíram para o refinamento do modelo XGB, mesmo assim sua interação pode ser importante.

Figura 44: Pontuação de relevância dos atributos da BD #2 para divisão dos nós pelo algoritmo XGB.

4.2.3 Desenvolvimento WEB

Uma aplicação WEB foi desenvolvida como ferramenta para simulações da vazão de labirintos como uma função de suas características geométricas e pressão de operação. O usuário preenche um formulário contendo os valores de entrada e obtém os valores estimados de vazão, estimado pelas características do sistema com uso dos modelos baseados em regressões não-lineares por NLS (Eq. 6) e por algoritmos computacionais (MLP, SVR e XGB). Adicionalmente, a curva vazão-pressão é construída para o usuário com passos de carga de pressão de 5 em 5 m. A interface da página WEB foi programada utilizando de linguagens HTML, CSS e JavaScript, enquanto os modelos gerados por algoritmo são carregados em Python. A aplicação WEB está disponibilizada no endereço <http://edischarge.pythonanywhere.com/>.

Na Figura 45 apresentam-se simulações com uso do aplicativo WEB, em incrementos de carga de pressão de 5 m (a) e 2,5 m (b). Para o incremento de 5 m nas cargas de pressão, observa-se que o modelo XGB apresentou um comportamento bem representativo do fenômeno em questão (Fig. 45a). Contudo, este incremento coincide com os valores utilizados para treinamento dos modelos. Se a simulação ocorrer com incrementos de 2,5 m (Fig. 45b), as estimativas obtidas pelo XGB são insatisfatórias e não representam o que se espera nesse fenômeno. O comportamento da curva obtida por XGB não se mantém suavizado (Fig. 45b) quando o intervalo de pontos amostrado não é múltiplo dos incrementos na base de dados, e isto é ainda mais acentuado para os valores contínuos de V na BD #1. Ou seja, a indução por árvore de decisão XGB apresentou a melhor representação para instâncias não observadas desta base, contanto que as instâncias de teste estejam descritas em termos correlacionados com os exemplos de treinamento

Figura 45: Representação hipotética das curvas q versus h retornadas pelo aplicativo WEB, com (a) intervalo de 5 m, e; (b) intervalo de 2,5 m

5 CONCLUSÃO

Sobre a BD #1 conclui-se que,

1. Os conectores iniciais com alargamentos bruscos de seção apresentaram as maiores perdas localizadas de carga. Assim, sugere-se aos fabricantes cuidados no desenho de conectores propondo minimizar as perdas.
2. O modelo MLP apresentou o desempenho mais satisfatório para o conjunto de dados avaliado pois exibiu uma função discriminatória bem ajustada aos pontos observados, mantendo uma representação mais próxima do fenômeno e de modelos NLS dedicados, além de um custo de treino aceitável.
3. O modelo SVR apresentou o erro mínimo com uso do mapeamento pela função RBF. Contudo, o treinamento com muitos dados foi expressivamente o mais custoso e o espaço de decisão pode ser mais prejudicado por ruídos.
4. O modelo XGB forneceu uma boa acurácia mesmo com um modelo simples, mas foi incoerente na estimativa da curva de hf_L em função de V , que deve sempre seguir uma função potencial. Entretanto, o algoritmo cumpriu com sua proposta de baixo custo computacional.
5. O modelo NLS genérico apresentou erros maiores entre todas as técnicas avaliadas, embora consistentes com o fenômeno físico. A variação de erro foi máxima nos conectores do tipo Y_{SC} e mínima no modelo I_{UC} em decorrência de complexidades geométricas dessas peças.

Relacionados com a BD #2

1. Observa-se que o uso de MLP necessita de uma alimentação massiva de informação, embora tenha apresentado um erro aproximado ao modelo matemático. Uma única camada proporcionou a capacidade de generalização mais eficiente em ambas bases enquanto mantém simplicidade ao modelo.
2. O modelo SVR mostrou-se bastante eficiente e com a rotina utilizada necessitou apenas da calibração de dois parâmetros convencionais. Obtiveram-se resultados satisfatórios, mesmo para a base de dados com poucas instâncias.
3. O modelo XGB forneceu uma boa acurácia, mas pode se tornar incoerente na estimativa da curva de vazão em função de carga de pressão, que deve sempre seguir uma função potencial.
4. O modelo NLS apresentou erro um pouco acima dos demais. Ainda assim, demandou esforços dos autores por tentativa e erro para a construção da relação matemática adequada.
5. O custo computacional foi insignificante para todos os modelos avaliados e isso é devido ao pequeno conjunto de dados avaliado.

REFERÊNCIAS

- ABADI, M., P. BARHAM, J. CHEN, Z. CHEN, A. DAVIS, J. DEAN, M. DEVIN, S. GHEMAWAT, G. IRVING, M. ISARD, *et al.*, 2016 Tensorflow: A system for large-scale machine learning. In *12th {USENIX} Symposium on Operating Systems Design and Implementation ({OSDI} 16)*, pp. 265–283.
- ABNT ISO 9261, 2006 *NBR ISO 9261. Equipamentos de irrigação agrícola: Emissores e tubos emissores - Especificações e métodos de ensaio*, São Paulo.
- AL-AMOUD, A. I., 1995 Significance of energy losses due to emitter connections in trickle irrigation lines. *Journal of Agricultural Engineering Research* **60**: 1–5.
- ARDIA, D., K. BOUDT, P. CARL, K. MULLEN, e B. PETERSON, 2010 Differential evolution with 'deoptim': An application to non-convex portfolio optimization. *The R Journal* **3**: 27–34.
- ARSLAN, M., M. GUZEL, M. DEMIRCI, e S. OZDEMIR, 2019 Smote and gaussian noise based sensor data augmentation. In *2019 4th International Conference on Computer Science and Engineering (UBMK)*, pp. 1–5, IEEE.
- AYACHI, E., S. IHCEN, e B. MOHAMED, 2012 A comparative study of nonlinear time-varying process modeling techniques: Application to chemical reactor. *Journal of Intelligent Learning Systems and Applications* **4**: 20.
- AZEVEDO NETO, J. M., 2015 *Manual de Hidráulica*. Edgard Blucher: São Paulo, 9th edition.
- BAGARELLO, V., V. FERRO, G. PROVENZANO, e D. PUMO, 1997 Evaluating pressure losses in drip-irrigation lines. *Journal of Irrigation and Drainage Engineering* **123**: 1–7.
- BASHEER, I. A. e M. HAJMEER, 2000 Artificial neural networks: fundamentals, computing, design, and application. *Journal of microbiological methods* **43**: 3–31.
- BATES, D., R. KIEGL, S. VASISHTH, e H. BAAYEN, 2015 Parsimonious mixed models. arXiv preprint arXiv:1506.04967 .
- BEHRENS, J. T., 1997 Principles and procedures of exploratory data analysis. *Psychological Methods* **2**: 131.
- BENEDIKTSSON, J. A., P. H. SWAIN, e O. K. ERSOY, 1990 Neural network approaches versus statistical methods in classification of multisource remote sensing data. *Transactions on Geoscience and Remote Sensing* **28**: 540–552.
- BENGIO, Y., 2012 Practical recommendations for gradient-based training of deep architectures. In *Neural networks: Tricks of the trade*, pp. 437–478, Springer.
- BOMBARDELLI, W., A. P. CAMARGO, R. LAVANHOLI, A. C. S. ARAUJO, M. V. TALAMINI JUNIOR, e J. A. FRIZZONE, 2017 Projeto e validação de uma bancada para ensaios de perda de carga localizada. *Brazilian Journal of Irrigation and Drainage* **1**.
- BOMBARDELLI, W. W., A. P. DE CAMARGO, J. A. FRIZZONE, R. LAVANHOLI, e H. S. DA ROCHA, 2019 Local head loss caused in connections used in micro-irrigation systems. *Revista Brasileira de Engenharia Agrícola e Ambiental-Agriambi* **23**.
- BOMBARDELLI, W. W. ., 2018 *Perda localizada de carga em conexões utilizadas em sistemas de microirrigação*. Ph.D. thesis, ESALQ/USP.
- BOTULA, Y.-D., A. NEMES, P. MAFUKA, E. VAN RANST, e W. M. CORNELIS, 2013 Prediction of water retention of soils from the humid tropics by the nonparametric k-nearest neighbor approach. *Vadose zone journal* **12**.
- BOX, G. e D. COX, 1964 An analysis of transformations. *Journal of the Royal Statistical Society* **26**: 211–252.
- BUCKINGHAM, E., 1914 On physically similar systems; illustrations of the use of dimensional equations. *Physical review* **4**: 345.
- BULLEN, P., D. CHEESEMAN, L. HUSSAIN, e A. RUFFELLT, 1987 The determination of pipe contraction pressure loss coefficients for incompressible turbulent flow. *International journal of heat and fluid flow* **8**: 111–118.
- CARDOSO, G. G. D. G. e J. A. FRIZZONE, 2007 Perda de carga em linhas laterais de microirrigação. *Revista Brasileira de Engenharia de Biosistemas* **1**: 147–162.
- CELIK, K., D. KARAYEL, M. LUPEANU, A. E. W. RENNIE, e I. AKINCI, 2015 Determination of head losses in drip irrigation laterals with cylindrical in-line type emitters through cfd analysis. *Bulgarian Journal of Agricultural Science* **21**: 703–710.
- CHAUHAN, S. e R. SHRIVASTAVA, 2009 Estimating reference evapotranspiration from limited climatic data using artificial neural networks. *ISH Journal of Hydraulic Engineering* **15**: 34–44.
- CHEN, T. e C. GUESTRIN, 2016 Xgboost: A scalable tree boosting system. In *Proceedings of the 22nd acm sigkdd international conference on knowledge discovery and data mining*, pp. 785–794, ACM.
- CHEN, Y. e Y. HAO, 2017 A feature weighted support vector machine and k-nearest neighbor algorithm for stock market indices prediction. *Expert Systems with Applications* **80**: 340–355.
- CHOLLET, F., 2018 *Deep learning with Python*. New York: Manning Publications.
- CORTES, C. e V. VAPNIK, 1995 Support-vector networks. *Machine Learning* **20**: 273–297.

- COVER, T. M., 1965 Geometrical and statistical properties of systems of linear inequalities with applications in pattern recognition. *IEEE transactions on electronic computers* pp. 326–334.
- CYBENKO, G., 1992 Approximation by superpositions of a sigmoidal function. *Mathematics of Control, Signals, and Systems (MCSS)* **5**: 455–455.
- DEMIR, V., H. YURDEM, e A. DEGIRMENCIOGLU, 2007 Development of prediction models for friction losses in drip irrigation laterals equipped with integrated in-line and on-line emitters using dimensional analysis. *Biosystems engineering* **96**: 617–631.
- DURAN-ROS, M., G. ARBAT, J. BARRAGÁN, F. R. DE CARTAGENA, e J. PUIG-BARGUÉS, 2010 Assessment of head loss equations developed with dimensional analysis for micro irrigation filters using effluents. *Biosystems engineering* **106**: 521–526.
- DURSUM, M. e S. ÖZDEN, 2014 An efficient improved photovoltaic irrigation system with artificial neural network based modeling of soil moisture distribution—a case study in turkey. *Computers and electronics in agriculture* **102**: 120–126.
- ELNESR, M. e A. ALAZBA, 2017 Simulation of water distribution under surface dripper using artificial neural networks. *Computers and Electronics in Agriculture* **143**: 90–99.
- FAN, J., X. WANG, L. WU, H. ZHOU, F. ZHANG, X. YU, X. LU, e Y. XIANG, 2018a Comparison of support vector machine and extreme gradient boosting for predicting daily global solar radiation using temperature and precipitation in humid subtropical climates: A case study in china. *Energy conversion and management* **164**: 102–111.
- FAN, J., W. YUE, L. WU, F. ZHANG, H. CAI, X. WANG, X. LU, e Y. XIANG, 2018b Evaluation of svm, elm and four tree-based ensemble models for predicting daily reference evapotranspiration using limited meteorological data in different climates of china. *Agricultural and forest meteorology* **263**: 225–241.
- FENG, J., Y. LI, W. WANG, e S. XUE, 2018 Effect of optimization forms of flow path on emitter hydraulic and anti-clogging performance in drip irrigation system. *Irrigation science* **36**: 37–47.
- FERRO, V., 1997 Applying hypothesis of self-similarity for flow-resistance law of small-diameter plastic pipes. *Journal of irrigation and drainage engineering* **123**: 175–179.
- FISHER, R. A. e M. MARSHALL, 1936 Iris data set. RA Fisher, UC Irvine Machine Learning Repository **440**: 87.
- FORTIN, F.-A., F.-M. DE RAINVILLE, M.-A. GARDNER, M. PARIZEAU, e C. GAGNÉ, 2012 DEAP: Evolutionary algorithms made easy. *Journal of Machine Learning Research* **13**: 2171–2175.
- FRIZZONE, J., P. D. FREITAS, R. REZENDE, e M. D. FARIA, 2012 *Microirrigação: gotejamento e microaspersão*. Maringá: Eduem.
- GARCÍA NIETO, P., E. GARCÍA-GONZALO, G. ARBAT, M. DURAN-ROS, F. R. DE CARTAGENA, e J. PUIG-BARGUÉS, 2016 A new predictive model for the filtered volume and outlet parameters in micro-irrigation sand filters fed with effluents using the hybrid pso-svm-based approach. *Computers and Electronics in Agriculture* **125**: 74–80.
- GARCÍA NIETO, P. J., E. GARCÍA-GONZALO, G. ARBAT, M. DURAN-ROS, F. R. DE CARTAGENA, e J. PUIG-BARGUÉS, 2018 Pressure drop modelling in sand filters in micro-irrigation using gradient boosted regression trees. *Biosystems engineering* **171**: 41–51.
- GARDNER, M. W. e S. DORLING, 1998 Artificial neural networks (the multilayer perceptron)—a review of applications in the atmospheric sciences. *Atmospheric environment* **32**: 2627–2636.
- GOMES, A. W. A., 2009 *Perda localizada de carga em gotejadores integrados em tubos de polietileno*. Ph.D. thesis, Universidade de São Paulo.
- GONG, Y. e C. POELLABAUER, 2017 Topic modeling based multi-modal depression detection. In *Proceedings of the 7th Annual Workshop on Audio/Visual Emotion Challenge*, pp. 69–76, ACM.
- GRANATA, F., 2019 Evapotranspiration evaluation models based on machine learning algorithms—a comparative study. *Agricultural Water Management* **217**: 303–315.
- GUAN, X., S. WANG, Z. GAO, e Y. LV, 2013 Dynamic prediction of soil salinization in an irrigation district based on the support vector machine. *Mathematical and Computer Modelling* **58**: 719–724.
- GUNTHER, F. e S. FRITSCH, 2010 neuralnet: Training of neural networks. *The R journal* **2**: 30–38.
- GUO, H., L. WANG, J. YU, F. YE, C. MA, e Z. LI, 2010 Local resistance of fluid flow across sudden contraction in small channels. *Frontiers of Energy and Power Engineering in China* **4**: 149–154.
- GUZMÁN, S. M., J. O. PAZ, M. L. M. TAGERT, A. E. MERCER, e J. W. POTE, 2018 An integrated svr and crop model to estimate the impacts of irrigation on daily groundwater levels. *Agricultural systems* **159**: 248–259.
- HAN, J. e C. MORAGA, 1995 The influence of the sigmoid function parameters on the speed of backpropagation learning. In *International Workshop on Artificial Neural Networks*, pp. 195–201, Springer.
- HAOSU, S., L. YUNKAI, F. JI, H. LIU, e Y. LIU, 2016 Effects of flow path boundary optimizations on particle transport in drip irrigation emitters. *Irrigation and Drainage* **65**: 417–425.
- HAYKIN, S., 2005 *Neural networks: a comprehensive foundation*, volume 13. Delhi: Pearson Education, 9th edition.

- HINNELL, A., N. LAZAROVITCH, A. FURMAN, M. POULTON, e A. WARRICK, 2010 Neuro-drip: estimation of subsurface wetting patterns for drip irrigation using neural networks. *Irrigation science* **28**: 535–544.
- HOERL, A. E. e R. W. KENNARD, 1970 Ridge regression: Biased estimation for nonorthogonal problems. *Technometrics* **12**: 55–67.
- HORNIK, K., M. STINCHCOMBE, e H. WHITE, 1989 Multilayer feedforward networks are universal approximators. *Neural networks* **2**: 359–366.
- JAIN, A. K., J. MAO, e K. M. MOHIUDDIN, 1996 Artificial neural networks: A tutorial. *Computer* **29**: 31–44.
- JAMES, G., D. WITTEN, T. HASTIE, e R. TIBSHIRANI, 2013 *An introduction to statistical learning*, volume 112. Springer.
- JUANA, L., L. RODRÍGUEZ SINOBAS, e A. LOSADA, 2002a Determining minor head losses in drip irrigation laterals. i: Methodology. *Journal of irrigation and Drainage Engineering* **128**: 376–384.
- JUANA, L., L. RODRÍGUEZ SINOBAS, e A. LOSADA, 2002b Determining minor head losses in drip irrigation laterals. ii: Experimental study and validation. *Journal of irrigation and drainage engineering* **128**: 385–396.
- KINGMA, D. P. e J. BA, 2014 Adam: A method for stochastic optimization. arXiv preprint arXiv:1412.6980 .
- KOMOROWSKI, M., D. C. MARSHALL, J. D. SALCICCIOLI, e Y. CRUTAIN, 2016 Exploratory data analysis. In *Secondary Analysis of Electronic Health Records*, pp. 185–203, Springer.
- KOTOWSKI, A., H. SZEWCZYK, e W. CIEZAK, 2011 Entrance loss coefficients in pipe hydraulic systems. *Environment Protection Engineering* **37**: 105–117.
- KUHN, M., 2008 Building predictive models in r using the caret package. *Journal of Statistical Software, Articles* **28**: 1–26.
- KUMAR, M., N. RAGHUWANSHI, e R. SINGH, 2011 Artificial neural networks approach in evapotranspiration modeling: a review. *Irrigation science* **29**: 11–25.
- LAROCHELLE, H., Y. BENGIO, J. LOURADOUR, e P. LAMBLIN, 2009 Exploring strategies for training deep neural networks. *Journal of machine learning research* **10**: 1–40.
- LAVANHOLI, R., 2019 *Relação entre características geométricas e operacionais de labirintos gotejadores*. Ph.D. thesis, ESALQ/USP.
- LAVANHOLI, R., A. PIRES DE CAMARGO, W. W. Á. BOMBARDELLI, J. A. FRIZZONE, N. AIT-MOUHEB, E. ALBERTO DA SILVA, e F. CORREIA DE OLIVEIRA, 2020 Prediction of pressure–discharge curves of trapezoidal labyrinth channels from nonlinear regression and artificial neural networks. *Journal of Irrigation and Drainage Engineering* **146**: 04020018.
- LECUN, Y., Y. BENGIO, e G. HINTON, 2015 Deep learning. *nature* **521**: 436.
- LI, G., J. WANG, M. ALAM, e Y. ZHAO, 2006 Influence of geometrical parameters of labyrinth flow path of drip emitters on hydraulic and anti-clogging performance. *Transactions of the ASABE* **49**: 637–643.
- LIKHACHEV, E., 2003 Dependence of water viscosity on temperature and pressure. *Technical Physics* **48**.
- LOH, W.-Y., 2010 Tree-structured classifiers. *Wiley Interdisciplinary Reviews: Computational Statistics* **2**: 364–369.
- MARTIN, J. J., 1974 Expansion and contraction losses in fluid flow. *Chemical Engineering Education* pp. 138–140.
- MARTÍ, P., G. PROVENZANO, . ROYUELA, e G. PALAU-SALVADOR, 2009 Integrated emitter local loss prediction using artificial neural networks. *Journal of Irrigation and Drainage Engineering* **136**: 11–22.
- MATTAR, M. A. e A. I. ALAMOUD, 2015 Artificial neural networks for estimating the hydraulic performance of labyrinth-channel emitters. *Computers and Electronics in Agriculture* **114**: 189–201.
- MINSKY, M. e S. PAPERT, 1969 Perceptron: an introduction to computational geometry. The MIT Press, Cambridge, expanded edition **19**: 2.
- MODARESI, F. e S. ARAGHINEJAD, 2014 A comparative assessment of support vector machines, probabilistic neural networks, and k-nearest neighbor algorithms for water quality classification. *Water resources management* **28**: 4095–4111.
- NGUYEN, P. M., A. HAGHVERDI, J. DE PUE, Y.-D. BOTULA, K. V. LE, W. WAEGEMAN, e W. M. CORNELIS, 2017 Comparison of statistical regression and data-mining techniques in estimating soil water retention of tropical delta soils. *Biosystems engineering* **153**: 12–27.
- OGUTU, J. O., H.-P. PIEPHO, e T. SCHULZ-STREECK, 2011 A comparison of random forests, boosting and support vector machines for genomic selection. In *BMC proceedings*, volume 5, p. 11, Springer.
- PEDREGOSA, F., G. VAROQUAUX, A. GRAMFORT, V. MICHEL, B. THIRION, O. GRISEL, M. BLONDEL, P. PRETTENHOFER, R. WEISS, V. DUBOURG, J. VANDERPLAS, A. PASSOS, D. COUNAPEAU, M. BRUCHER, M. PERROT, e E. DUCHESNAY, 2011 Scikit-learn: Machine learning in Python. *Journal of Machine Learning Research* **12**: 2825–2830.
- PERBONI, A., J. A. FRIZZONE, A. P. D. CAMARGO, e M. F. PINTO, 2015 Modelling head loss along emitting pipes using dimensional analysis. *Engenharia Agrícola* **35**: 442–457.

- PERBONI, A., J. A. FRIZZONE, e A. P. DE CAMARGO, 2014 Artificial neural network based equation to estimate head loss along drip irrigation laterals. *Revista Brasileira de Agricultura Irrigada* **8**: 77.
- PINTO, M. F., A. P. D. CAMARGO, O. RETTORE NETO, e J. A. FRIZZONE, 2014 Caracterização hidráulica de tubos porosos oriundos de pneus reciclados utilizados em irrigação subsuperficial. *Revista Brasileira de Engenharia Agrícola e Ambiental* **18**: 1095–1101.
- PORTO, R. D. M., 1998 *Hidráulica básica*, volume 4. São Carlos: EESC/USP.
- PROVENZANO, G. e D. PUMO, 2004 Experimental analysis of local pressure losses for microirrigation laterals. *Journal of Irrigation and Drainage Engineering* **130**: 318–324.
- PUIG-BARGUÉS, J., J. BARRAGÁN, e F. R. DE CARTAGENA, 2005 Development of equations for calculating the head loss in effluent filtration in microirrigation systems using dimensional analysis. *Biosystems Engineering* **92**: 383–390.
- PUIG-BARGUÉS, J., M. DURAN-ROS, G. ARBAT, J. BARRAGÁN, e F. R. DE CARTAGENA, 2012 Prediction by neural networks of filtered volume and outlet parameters in micro-irrigation sand filters using effluents. *Biosystems engineering* **111**: 126–132.
- RETTORRE NETO, O., J. H. DE MIRANDA, J. A. FRIZZONE, e S. R. WORKMAN, 2009a Local head loss of non-coaxial emitters inserted in polyethylene pipe. *Transactions of the ASABE* **52**: 729.
- RETTORRE NETO, O., J. A. FRIZZONE, J. H. MIRANDA, e T. A. BOTREL, 2009b Perda de carga localizada em emissores não coaxiais integrados a tubos de polietileno. *Engenharia Agrícola* **29**: 28–39.
- ROCHA, H. S. D., P. A. MARQUES, A. P. D. CAMARGO, J. A. FRIZZONE, e E. SARETTA, 2017 Internal surface roughness of plastic pipes for irrigation. *Revista Brasileira de Engenharia Agrícola e Ambiental* **21**: 143–149.
- ROSENBLATT, F., 1957 *The perceptron, a perceiving and recognizing automaton*. Cornell Aeronautical Laboratory.
- RUDER, S., 2016 An overview of gradient descent optimization algorithms. arXiv preprint arXiv:1609.04747 .
- RUMELHART, D. E., G. E. HINTON, e R. J. WILLIAMS, 1986 Learning representations by back-propagating errors. *nature* **323**: 533.
- SANDULESCU, V. e M. CHIRU, 2016 Predicting the future relevance of research institutions-the winning solution of the kdd cup 2016. arXiv preprint arXiv:1609.02728 .
- SCHALKOFF, R. J., 2007 Pattern recognition. *Wiley Encyclopedia of Computer Science and Engineering* .
- SINGH, S. e P. GUPTA, 2014 Comparative study id3, cart and c4.5 - decision tree algorithm: a survey. *International Journal of Advanced Information Science and Technology (IJAIST)* **27**: 97–103.
- SMOLA, A. J. e B. SCHÖLKOPF, 2004 A tutorial on support vector regression. *Statistics and computing* **14**: 199–222.
- SOBENKO, L. R., J. A. FRIZZONE, A. P. D. CAMARGO, E. SARETTA, e H. S. D. ROCHA, 2019 Caracterização de injetor venturi utilizando análise dimensional. *Revista Brasileira de Engenharia Agrícola e Ambiental* **23**: 484–491.
- STORN, R. e K. PRICE, 1997 Differential evolution—a simple and efficient heuristic for global optimization over continuous spaces. *Journal of global optimization* **11**: 341–359.
- SWAMEE, P. K., 1993 Design of a submarine oil pipeline. *Journal of transportation Engineering* **119**: 159–170.
- TANAKA, M., G. GIRARD, R. DAVIS, A. PEUTO, e N. BIGNELL, 2001 Recommended table for the density of water between 0 c and 40 c based on recent experimental reports. *Metrologia* **38**: 301.
- TORGO, L., P. BRANCO, R. P. RIBEIRO, e B. PFAHRINGER, 2015 Resampling strategies for regression. *Expert Systems* **32**: 465–476.
- TORGO, L., R. P. RIBEIRO, B. PFAHRINGER, e P. BRANCO, 2013 Smote for regression. In *Portuguese conference on artificial intelligence*, pp. 378–389, Springer.
- TSAKIRIS, G. e V. TSAKIRIS, 2012 Pipe technologies for urban water conveyance distribution systems. *Water Utility Journal* **3**: 29–36.
- VEKARIYA, P., R. SUBBAIAH, e H. MASHRU, 2011 Hydraulics of microtube emitters: a dimensional analysis approach. *Irrigation Science* **29**: 341–350.
- VENKATANAGENDRA, K. e D. MALIGELAUSSENAIAH, 2017 Classification of rainfall data using linear kernel based support vector machines. *Int. J. Appl. Eng. Res* **12**: 9717–9722.
- VILAÇA, F. N., A. P. DE CAMARGO, J. A. FRIZZONE, L. MATEOS, e R. KOECH, 2017 Minor losses in start connectors of microirrigation laterals. *Irrigation science* **35**: 227–240.
- VOLKOV, M., G. W. YU, e T. POUTANEN, 2017 Content-based neighbor models for cold start in recommender systems. In *Proceedings of the Recommender Systems Challenge 2017*, p. 7, ACM.
- WEI, Q., Y. SHI, W. DONG, G. LU, e S. HUANG, 2006 Study on hydraulic performance of drip emitters by computational fluid dynamics. *Agricultural Water Management* **84**: 130–136.
- WERBOS, P. J. *et al.*, 1990 Backpropagation through time: what it does and how to do it. *Proceedings of the IEEE* **78**: 1550–1560.

- WU, W., W. CHEN, H. LIU, S. YIN, e Y. NIU, 2014 A new model for head loss assessment of screen filters developed with dimensional analysis in drip irrigation systems. *Irrigation and drainage* **63**: 523–531.
- YILDIRIM, G., 2007 An assessment of hydraulic design of trickle laterals considering effect of minor losses. *Irrigation and Drainage: The journal of the International Commission on Irrigation and Drainage* **56**: 399–421.
- YILDIRIM, G., 2010 Total energy loss assessment for trickle lateral lines equipped with integrated in-line and on-line emitters. *Irrigation science* **28**: 341–352.
- YILDIRIM, G. e N. AGIRLIOGLU, 2004 Comparative analysis of hydraulic calculation methods in design of microirrigation laterals. *Journal of Irrigation and Drainage Engineering* **130**: 201–217.
- YONG, D., T. OKIISHI, e B. MUNSON, 2004 *Fundamentos da mecânica dos fluidos*. Edgard Blucher.
- YU, L., N. LI, X. LIU, Q. YANG, Z. LI, e J. LONG, 2019 Influence of dentation angle of labyrinth channel of drip emitters on hydraulic and anti-clogging performance. *Irrigation and Drainage* **68**: 256–267.
- YURDEM, H., V. DEMIR, e A. DEGIRMENCIOGLU, 2008 Development of a mathematical model to predict head losses from disc filters in drip irrigation systems using dimensional analysis. *Biosystems Engineering* **100**: 14–23.
- ZANETTI, S., E. SOUSA, V. OLIVEIRA, F. ALMEIDA, e S. BERNARDO, 2007 Estimating evapotranspiration using artificial neural network and minimum climatological data. *Journal of Irrigation and Drainage Engineering* **133**: 83–89.
- ZHANG, J., W. ZHAO, e B. LU, 2012 Rapid prediction of hydraulic performance for emitters with labyrinth channels. *Journal of Irrigation and Drainage Engineering* **139**: 414–418.
- ZITTERELL, D. B., J. A. FRIZZONE, e O. RETTORE NETO, 2014 Dimensional analysis approach to estimate local head losses in microirrigation connectors. *Irrigation Science* **32**: 169–179.

APÊNDICES

Apêndice I - Distribuição dos dados da BD #1: Bases dedicadas

Apêndice II - Distribuição dos dados da BD #1: Base generalizada

Apêndice III - Distribuição dos dados da BD #2: Base completa

Apêndice IV - Modelos característicos para cada código ou tipo

Figura A.1: Distribuição dos dados obtidos por ensaios dos conectores do tipo I_{SC}. Linha pontilhada corresponde aos valores médios e é informada nos dados brutos coletados da bancada e transformados em função da temperatura.

Figura A.2: Distribuição dos dados obtidos por ensaios dos conectores do tipo I_{SCV}

Figura A.3: Distribuição dos dados obtidos por ensaios dos conectores do tipo Ysc

Figura A.4: Distribuição dos dados obtidos por ensaios dos conectores do tipo IUC

Figura A.5: Distribuição dos dados obtidos por ensaios dos conectores do tipo IUCV

Figura A.6: Distribuição dos dados obtidos por ensaios dos conectores do tipo Yuc

Figura A.7: Distribuição dos dados obtidos por ensaios dos conectores do tipo T_{GC}

Figura A.8: Distribuição de todos dados obtidos por ensaios da BD #1

Figura A.9: Distribuição dos dados obtidos por ensaios da BD #2

Tipo	Código	K_L ($hf_L = K_L V^2/2g$)	Eq. Específica
I _{SC}	37	10,019	$hf_L = 0,0489 \frac{V^{1,9968} v^{0,0032} L_C^{0,3030} D_L^{3,7395}}{D_{in}^{3,8611} D_{out}^{0,1845}}$
	46	23,936	
	57	5,646	
	58	10,543	
	186	23,724	
I _{VSC}	150	19,192	$hf_L = 0,0863 \frac{V^{1,9919} v^{0,0081} L_{in}^{0,8289} D_L^{3,8448}}{D_{in}^{3,7489} D_{out}^{0,3261} D_G^{0,1953} L_{out}^{0,4115}}$
	152	9,574	
	182	20,990	
Y _{SC}	181	8,754	$hf_L = 0,0504 \frac{V^{2,0286} L_{out}^{0,9473} D_L^{4,7000}}{v^{0,0286} D_{in}^{1,2089} D_{out}^{1,3201} L_{in}^{3,0895}}$
	208	14,444	
	234	37,702	
	237	20,177	
I _{UC}	38	2,720	$hf_L = 0,0157 \frac{V^{1,9946} D_L^{4,5710} L_C^{0,4236} v^{0,0055}}{D_i^5}$
	81	3,699	
	82	3,115	
I _{VUC}	151	18,860	$hf_L = 0,0118 \frac{V^{2,0134} D_L^{4,2341} L_C^{0,9641}}{v^{0,0134} D_i^{3,5032} D_G^{1,6816}}$
	153	8,361	
	212	14,317	
Y _{UC}	180	3,550	$hf_L = 0,2036 \frac{V^{1,9807} v^{0,0193} D_L^{1,6491} D_{out}^{4,9933} L_{out}^{0,3091}}{D_{in}^{4,9885} L_{in}^{1,9823}}$
	204	5,357	
	232	22,968	
T _{UC}	109	19,811	$hf_L = 0,0034 \frac{v^{0,1076} V^{1,8924} D_i^{0,5441} L_i^5}{D_L^{5,6517}}$
	164	8,969	

Figura A.10: Modelos característicos de hf_L , dedicados aos códigos e às classes. Em que, hf_L : perda localizada por conectores iniciais (SC) e de união (UC), do tipo I sem ou com registros (Iv), do tipo T e do tipo Y, (m); V: velocidade média de escoamento, ($m\ s^{-1}$); ν : viscosidade cinemática da água, (m^2s^{-1}); D_L : diâmetro interno da lateral, (m); D_{in} e D_{out} : respectivos diâmetros de entrada e saída, (m); D_G : diâmetro da garganta no caso de registros, (m), L_{in} e L_{out} : respectivos comprimentos de entrada e saída, (m), D_i : diâmetro interno médio $\frac{D_{in}+D_{out}}{2}$, (m); L_i : comprimento médio dos trechos, $\frac{L_{in}+L_{out}}{2}$, (m) e; L_c : comprimento total, $L_{in}+L_{out}$, (m).