



Universidade do Estado do Rio de Janeiro

Centro de Tecnologia e Ciências

Faculdade de Engenharia

José Rodrigo de Castro Silva

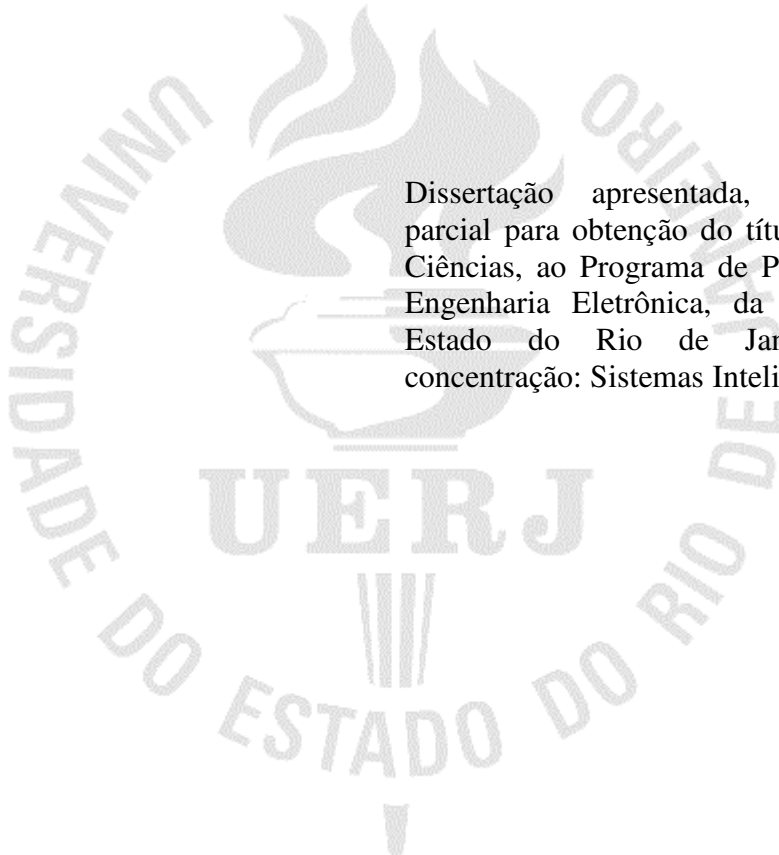
**Algoritmos de aprendizado de máquinas aplicados na inferência de vazão
de um medidor de vazão por efeito térmico**

Rio de Janeiro

2020

José Rodrigo de Castro Silva

**Algoritmos de aprendizado de máquinas aplicados na inferência de vazão de um
medidor de vazão por efeito térmico**



Dissertação apresentada, como requisito parcial para obtenção do título de Mestre em Ciências, ao Programa de Pós-Graduação em Engenharia Eletrônica, da Universidade do Estado do Rio de Janeiro. Área de concentração: Sistemas Inteligentes.

Orientador: Prof. Dr. Jorge Luís Machado do Amaral

Rio de Janeiro

2020

CATALOGAÇÃO NA FONTE
UERJ / REDE SIRIUS / BIBLIOTECA CTC/B

S586 Silva, José Rodrigo de Castro.
Algoritmos de aprendizado de máquinas aplicados na inferência de vazão de um medidor de vazão por efeito térmico / José Rodrigo de Castro Silva. – 2020.
97f.

Orientador: Jorge Luís Machado do Amaral.
Dissertação (Mestrado) – Universidade do Estado do Rio de Janeiro, Faculdade de Engenharia.

1. Engenharia eletrônica - Teses. 2. Medidores de fluxo - Teses. 3. Redes neurais (Computação) - Teses. 4. Aprendizado do computador - Teses. 5. Calorimetria - Teses. 6. Detectores - Teses. I. Amaral, Jorge Luís Machado do. II. Universidade do Estado do Rio de Janeiro, Faculdade de Engenharia. III. Título.

CDU 004.89

Bibliotecária: Júlia Vieira – CRB7/6022

Autorizo, apenas para fins acadêmicos e científicos, a reprodução total ou parcial desta tese, desde que citada a fonte.

Assinatura

Data

José Rodrigo de Castro Silva

**Algoritmos de aprendizado de máquinas aplicados na inferência de vazão de um
medidor de vazão por efeito térmico**

Dissertação apresentada, como requisito parcial para obtenção do título de Mestre em Ciências, ao Programa de Pós-Graduação em Engenharia Eletrônica, da Universidade do Estado do Rio de Janeiro. Área de concentração: Sistemas Inteligentes.

Aprovado em 13 de outubro de 2020.

Banca Examinadora:

Prof. Dr. Jorge Luís Machado do Amaral (Orientador)
Faculdade de Engenharia – UERJ

Prof. Dr. Juan Moises Mauricio Villanueva
Universidade Federal da Paraíba

Prof. Dr. Daniel José Nahid Mansur Chalhub
Faculdade de Engenharia - UERJ

Rio de Janeiro

2020

DEDICATÓRIA

Dedico este trabalho ao meu pai, senhor Reginaldo José, o meu maior exemplo de vida.

AGRADECIMENTOS

A Deus por ser a minha força e me fazer andar em lugares altos.

Ao professor Jorge Luís Machado do Amaral por toda paciência e confiança que excederam minhas expectativas durante a orientação deste trabalho.

À minha esposa Brunna Arêas por compreender minhas angústias e, em todas as ocasiões, me dar força e apoio para continuar trabalhando e estudando.

À minha mãe Célia Regina e ao meu irmão Henrique Estácio por todo amor e energia que empregaram durante toda a minha vida para que hoje eu pudesse estar onde estou.

À professora Rita de Cássia Azevedo de Figueiredo, que foi minha orientadora na graduação, pela confiança ao me indicar para este programa de mestrado.

Aos amigos Tiago Quirino e Pedro Thompson pelas constantes ajudas e incentivos dados durante todo o curso. Serei eternamente grato pela confiança que depositaram em mim.

À juventude da Primeira Igreja Batista da Freguesia de Jacarepaguá por todas as orações e pelos momentos felizes que me proporcionaram durante este curso.

Aos colegas de curso Carlos Alberto, Nayara Villela, George Leandro, Elan Gonçalves e Allan Danilo por toda ajuda em cada disciplina.

Aos colegas de laboratório Sávio Andrade, Leandro Trindade e Everton Araújo por toda ajuda e empenho na construção e configuração da bancada de testes.

À Petrobras Transporte S.A – Transpetro, em especial aos colegas Adriano Moreira, Daniel Flores e Pedro Barcellos, por me proporcionar a chance de conciliar meu trabalho com meus estudos.

À UERJ por me proporcionar participar gratuitamente do seu programa de mestrado contribuindo ainda mais para o meu desenvolvimento social, intelectual, pessoal e profissional.

Fortis fortuna adiuvat.
(A sorte favorece os corajosos.)
Publio Terêncio de Cártago

RESUMO

SILVA, José R. C. *Algoritmos de aprendizado de máquinas aplicados na inferência de vazão de um medidor de vazão por efeito térmico*. 2020. 97f. Dissertação (Mestrado em Engenharia Eletrônica) – Faculdade de Engenharia, Universidade do Estado do Rio de Janeiro, Rio de Janeiro, 2020.

As técnicas de medição de vazão não-intrusivas atuais ainda carecem de melhorias pois têm desvantagens que são impeditivas para aplicações em pequenos diâmetros. Este trabalho busca desenvolver um medidor de vazão por efeito térmico não-intrusivo que utiliza algoritmos de aprendizado de máquinas para obtenção do menor erro de fundo de escala possível em baixas vazões de líquidos. O medidor utiliza um duto de cobre com diâmetro interno de 22mm, seis termopares comerciais do tipo k, uma resistência de aquecimento do tipo microtubular e uma inteligência artificial para inferir a vazão a partir da distribuição térmica na superfície do duto. A disposição dos sensores e do aquecedor foi calculada com base no espalhamento teórico de temperatura obtido na modelagem feita através do *software* COMSOL *Multiphysics*. Para avaliar o protótipo do medidor uma bancada de testes foi construída, a qual possibilita o controle da vazão e da temperatura da resistência de aquecimento. A bancada de testes é dotada de um medidor de vazão eletromagnético calibrado e certificado em laboratório externo o qual é utilizado para referência e comparação, conforme as orientações da ABNT e as boas práticas utilizadas nas indústrias e laboratórios de calibração. No experimento, a resistência foi acionada de modo que a temperatura na região central do duto permanecesse em 70°C e foram coletados os dados da distribuição térmica com vazões entre 0,05 e 0,6 m³/h com acréscimos intermediários de 0,01 m³/h. Os dados coletados fornecidos pelo experimento foram utilizados no treinamento dos seguintes modelos: regressão linear, *K-Nearest Neighbor* (K-NN), Árvore de Decisão, Florestas Aleatórias e *Gradient Boosting*. Além disso, também foram treinadas redes neurais artificiais *Perceptron* Multicamadas e modelos de Aprendizagem Profunda. O melhor resultado foi obtido com um modelo de aprendizagem profunda com a técnica *Dropout*, a qual demonstrou que o protótipo construído tem a capacidade de inferir a vazão com erro de fundo de escala igual a 1,8%. O experimento demonstrou que o uso de algoritmos de aprendizado de máquinas pode ser usado para melhorias em sistemas de medição de vazão não-intrusivos.

Palavras chave: Medição de Vazão; Rede Neural; Aprendizado de Máquinas; Vazão Termal; Calorimetria; Sensor Inteligente; Não Intrusivo.

ABSTRACT

SILVA, José R. C. *Machine learning algorithms applied to the flow inference of a thermal flow meter*. 2020. 97f. Dissertação (Mestrado em Engenharia Eletrônica) – Faculdade de Engenharia, Universidade do Estado do Rio de Janeiro, Rio de Janeiro, 2020.

Current non-intrusive flow measurement techniques still need improvements as they have disadvantages small diameter applications. This work proposes to develop a non-intrusive thermal flow meter that uses machine learning algorithms to obtain the smallest full-scale deflection possible in low liquid flows. The meter uses a copper duct with an internal diameter of 22mm, six commercial k-type thermocouples, a microtubular heating resistance, and an artificial intelligence to infer the flow rate from the thermal distribution on the duct surface. The sensors and the heater layout was calculated based on the theoretical temperature spread obtained in the modeling done using the COMSOL Multiphysics software. To evaluate the meter, a test bench was built to control the flow rate and temperature of the heating resistor. The test bench is equipped with an electromagnetic flowmeter calibrated and certified in an external laboratory, which is used for reference and comparison, according to the ABNT guidelines and the good practices used in the industries and calibration laboratories. In the experiment, the resistance was activated so that the temperature in the central region of the duct remained at 70 ° C and the thermal distribution data was collected with flow rates between 0.05 and 0.6 m³/h with intermediate increases of 0.01 m³/h. The collected data provided by the experiment were used to train the following models: linear regression, K-Nearest Neighbor (K-NN), Decision Tree, Random Forests and Gradient Boosting. Besides, Multilayer Perceptron and Deep Learning models were also trained. The best result was obtained with the Dropout technique, which demonstrated that the built prototype can infer the flow with a full scale deflection equal to 1.8%. The experiment demonstrated that the use of machine learning algorithms could be used to improve non-intrusive flow measurement systems.

Keywords: Flow Measurement; Neural Network; Machine Learning; Thermal Flow; Calorimetry; Smart Sensor; Non Intrusive.

LISTA DE FIGURAS

Figura 1 – Distribuição de velocidade entre placas paralelas.....	21
Figura 2 – Regimes de Escoamento.....	22
Figura 3 - Características das medições.....	23
Figura 4 – Escoamento através de uma redução de área.....	24
Figura 5 – Modelos de placas de orifício.....	24
Figura 6 – Esquemático de um tubo de Venturi.....	25
Figura 7 – Modelos de Medidores Annubar do fabricante Emerson.....	25
Figura 8 – Modelo de Medidor do Tipo VORTEX.....	26
Figura 9 – Estágios de um Medidor do Tipo Deslocamento Positivo.....	27
Figura 10 – Medidor do Tipo Turbina.....	27
Figura 11 – Medidor do Tipo Ultrassônico.....	29
Figura 12 – Medidor do Tipo Coriolis.....	29
Figura 13 – Medidor de vazão eletromagnético.....	30
Figura 14 – Funcionamento de um medidor de vazão eletromagnético.....	30
Figura 15 – Medidor por FIV.....	31
Figura 16 – Experiência de LV King.....	32
Figura 17 – Aquisição e processamento dos dados para medição de vazão termal.....	34
Figura 18 – Arranjo típico de um anemômetro térmico.....	35
Figura 19 – Arranjo de um anemômetro térmico por tempo de trânsito.....	36
Figura 20 – Medidor de vazão por convecção forçada.....	36
Figura 21 – Medidor de vazão por oscilação térmica.....	37
Figura 22 – Gráfico de oscilação térmica.....	38
Figura 23 – Calorímetro Típico.....	38
Figura 24 – Perfis típicos do gradiente de temperatura.....	39
Figura 25 – Variação do $c_{p,água}$	41
Figura 26 – Variação do $k_{,água}$	42
Figura 27 – Variação do $\rho_{,água}$	43
Figura 28 – Variação do $\eta_{,água}$	44
Figura 29 – Curva de convergência do modelo em elementos finitos.....	46
Figura 30 – Distribuição da temperatura	46

Figura 31 – Distribuição teórica da temperatura na superfície do tubo (°C).....	47
Figura 32 – Perfil de temperatura em função da vazão simulado no COMSOL.....	47
Figura 33 – Perfil de temperatura simulado no COMSOL com representação dos sensores instalados.....	48
Figura 34 – Distribuição teórica de velocidade no fluido (m/s).....	48
Figura 35 – Perfil teórico da velocidade do fluido.....	49
Figura 36 – Resistência elétrica microtubular	50
Figura 37 – Resistência acoplada ao duto.....	51
Figura 38 – Medidor de vazão termal (MVT).....	52
Figura 39 – Duto com resistência elétrica e termopares acoplados.....	52
Figura 40 – Protótipo instalado na bancada.....	52
Figura 41 – Diagrama de instrumentação da bancada.....	53
Figura 42 – Bancada com o protótipo em destaque.....	55
Figura 43 –Supervisório <i>Labview</i> – tela de comando.....	56
Figura 44 – Supervisório <i>Labview</i> – tela de aquisição.....	57
Figura 45 – Esquema de um modelo de Árvore de Decisão simplificado em dois níveis.....	61
Figura 46 – RNA de camada única.....	63
Figura 47 – RNA multicamadas.....	64
Figura 48 – Exemplo de <i>Dropout</i>	66
Figura 49 – Representação típica do modelo de regressão multivariado.....	68
Figura 50 - Representação dos modelos de RNA e AM.....	68
Figura 51 – Perfil das temperaturas no duto em função da vazão na bancada.....	69
Figura 52 – Perfil de temperatura obtido no experimento por intervalos de vazão.....	69
Figura 53 – Comparativo Modelagem x Experimento.....	70
Figura 54 – Média dos erros absolutos entre as temperaturas de todos os termopares previstas no modelo e medidas no experimento por faixa de vazão.....	70
Figura 55 – Projeto conceitual de sistema de aprendizado de máquinas aplicado ao MVT....	71
Figura 56 – Dados adquiridos sem tratamento.....	71
Figura 57 – Dados adquiridos após a filtragem.....	72
Figura 58 – Perfil típico das vazões e temperaturas dos sensores.....	73
Figura 59 – Vazão real e vazão prevista pelo modelo de AM <i>Gradient Boosting</i>	75
Figura 60 – Erro fiducial de 0.06 a 0.33m ³ /h.....	76
Figura 61 – Erro fiducial de 0.34 a 0.60m ³ /h.....	76
Figura 62 – Representação dos modelos de RNA e AM usando o Δ Temp.....	77

Figura 63 – Vazões e diferenciais de temperatura (Δ Temp).....	77
Figura 64 – Conjunto de teste ordenado.....	78
Figura 65 – Vazão real e vazão prevista pelo modelo de RNA <i>Dropout</i>	79
Figura 66 – Erro fiducial de 0.06 a 0.33m ³ /h (Δ Temp).....	80
Figura 67 – Erro fiducial de 0.34 a 0.60m ³ /h (Δ Temp).....	80

LISTA DE TABELAS

Tabela 1 – Dimensões primárias e unidades nos sistemas SI e BG.....	20
Tabela 2 – Viscosidade e densidade de alguns fluidos ($p=p_{atm}$; $T=20^{\circ}C$).....	21
Tabela 3 – Tabela comparativa dos principais medidores de vazão usados em tubulações.....	32
Tabela 4 – Melhores modelos obtidos de cada algoritmo proposto ($k=10$).....	74
Tabela 5 – Melhores modelos segundo o critério do erro de fundo de escala.....	75
Tabela 6 – Melhores modelos obtidos pelos algoritmos propostos ($\Delta Temp$)	78
Tabela 7 – Melhores modelos segundo o critério do erro de fundo de escala ($\Delta Temp$)	79

LISTA DE SIGLAS

ABNT	Associação Brasileira de Normas Técnicas
AM	Aprendizado de Máquinas
ABS	<i>Acrylonitrile Butadiene Styrene</i>
BG	<i>British Gravitational Units</i>
DL	<i>Deep Learning</i>
EMQ	Erro Médio Quadrático
GD	Gradiente Descendente
kNN	<i>k-Nearest Neighbors</i>
LARISA	Laboratório de Redes Industriais e Sistemas de Automação
MLP	<i>Multi Layer Perceptron</i>
MMQ	Método dos Mínimos Quadrados
MRL	Modelo de Regressão Linear
MVA	Média de Valores Absolutos
MVT	Medidor de Vazão Termal
PDM	<i>Positive Displacement Meter</i>
PDT	<i>Pressure Differential Transmitter</i>
PID	Proporcional Integral Derivativo
PWM	<i>Pulse-Width Modulation</i>
RBC	Rede Brasileira de Calibração
RNA	Redes Neurais Artificiais
SGD	<i>Stochastic Gradient Descent</i>
SI	Sistema Internacional

LISTA DE SÍMBOLOS

∇	Operador gradiente
ΔP	Diferencial de pressão
ΔTemp	Diferencial de Temperatura
Θ	Conjunto de parâmetros
τ	Índice de interação
η	Taxa de aprendizado
\bar{k}	Condutividade térmica média
ε	Resíduos da regressão linear
W	Matriz dos pesos
i	Época de treinamento
S	Condutividade
V	volt
$^{\circ}\text{C}$	Grau Celsius
mA	miliampére
Re	Número de Reynolds
D	Diâmetro
V_m	Velocidade média
ρ	Massa específica
μ	Viscosidade
K	Constante de proporcionalidade

SUMÁRIO

	INTRODUÇÃO	16
1	MEDIÇÃO DE VAZÃO	20
1.1	Medidores de Vazão	23
1.1.1	<u>Medidores Deprimogênios</u>	23
1.1.2	<u>Tipo VORTEX</u>	26
1.1.3	<u>Deslocamento Positivo</u>	27
1.1.4	<u>Turbina</u>	27
1.1.5	<u>Ultrassônicos</u>	28
1.1.6	<u>Tipo Coriolis (Mássicos)</u>	29
1.1.7	<u>Eletromagnéticos</u>	30
1.1.8	<u>Vibração Induzida pelo Fluxo</u>	31
1.1.9	<u>Termais</u>	31
1.2	Comparação entre as Tecnologias de Medição de Vazão	32
2	TECNOLOGIAS TERMAIS DE MEDIÇÃO DE VAZÃO	34
2.1	Anemômetro Térmico	34
2.2	Tempo de Trânsito	36
2.3	Convecção Forçada	36
2.4	Oscilação Térmica	37
2.5	Calorímetro	38
2.6	Simulação através do COMSOL	39
3	CONSTRUÇÃO DO MEDIDOR E DA BANCADA DE TESTES	50
3.1	Construção do protótipo	50
3.2	Bancada e Supervisório	53
3.3	Aquisição e tratamento dos dados	56
3.4	Métodos de aprendizado de máquinas para inferência da vazão	57
3.4.1	<u>Regressão linear múltipla</u>	59
3.4.2	<u>Algoritmo kNN Regressor</u>	60
3.4.3	<u>Árvore de Decisão</u>	60
3.4.4	<u>Florestas Aleatórias</u>	62
3.4.5	<u>Gradient Boosting Regressor</u>	62
3.5	Rede Neural Artificial	63

3.5.1	<u>Redes neurais artificiais do tipo <i>feed-forward</i></u>	63
3.5.2	<u>Aprendizagem Profunda</u>	65
3.5.3	<u>Dropout</u>	66
4	RESULTADOS EXPERIMENTAIS	68
4.1	Resultados obtidos	73
	CONCLUSÕES	81
	REFERÊNCIAS	83
	ANEXO	92

INTRODUÇÃO

Medir vazão é uma atividade de grande importância em diversos setores tais como comércio, indústria e até na medicina. Em todas estas áreas, existem processos que exigem a medição de valores muito precisos e que englobam fluidos com diferentes condições e propriedades, as quais interferem na viabilidade de se realizar uma boa medição da vazão. Portanto, a escolha de um medidor depende de fatores como faixa de operação, exatidão demandada, tipo de produto e relação custo-benefício. Conseqüentemente, existe uma grande motivação de realizar pesquisas que possibilitem desenvolver medidores de vazão cada vez mais precisos e que atendam às características específicas de cada processo.

Existem várias formas de se realizar medição de vazão, e esta forma determinará a classificação do medidor. A forma de contato entre os sensores e o fluido determinará se o medidor é classificado como invasivo ou não-invasivo assim como a interferência que os sensores causam no escoamento determinará se o medidor é classificado como intrusivo ou não-intrusivo.

Medidores não-intrusivos, pelo fato dos seus sensores não terem contato direto com o fluido e não provocarem obstruções ao escoamento, apresentam uma série de vantagens tais como: não provocam perda de carga, não contaminam o produto, têm uma fácil instalação e são de fácil manutenção. Estas características dão mais destaque aos medidores de tecnologia não intrusiva quando comparados aos outros.

Medidores com tecnologias de indução magnética ou ultrassônica (efeito Doppler ou tempo de trânsito) embora sejam modelos não intrusivos amplamente utilizados e tenham muito destaque, apresentam algumas desvantagens. Medidores ultrassônicos, segundo Nnabuife (2019), têm seu desempenho muito afetado pelo perfil de vazão e são muito suscetíveis à presença de bolhas e a fluidos bifásicos. Ultrassônicos que utilizam efeito Doppler têm seu desempenho muito prejudicado por partículas suspensas enquanto que os que usam a técnica do tempo de trânsito não operam bem em diâmetros pequenos.

Já os que utilizam indução magnética, têm um custo muito elevado para pequenos diâmetros e só funcionam com fluidos que tenham uma condutividade mínima de $200 \mu\text{S/m}$, segundo Awwa (1989). As desvantagens observadas nestes modelos mais utilizados justificam pesquisar outras tecnologias de medição de vazão capazes de mitigar estes erros.

Trabalhos científicos recentes apontam que medidores de vazão térmicos são alternativas promissoras para medição de vazão não intrusiva. No artigo chamado “*Single-*

Element Thermal Flow Sensor using Dual-Slope Control Scheme” (CLOCKER et al., 2017) os autores apresentam uma arquitetura de um medidor de fluxo térmico que utiliza um único elemento resistivo para medir a vazão de um fluido com o uso de um algoritmo de controle e medição de duas fases. Neste artigo, é demonstrada a possibilidade de utilizar esta técnica em pequenos diâmetros. Em outro trabalho chamado “*Microneedle Thermal Flow Sensor*” (LEE et al., 2016) é apresentado um medidor de vazão térmico baseado em microagulhas para medição de fluxos de líquido em baixa velocidade. Nesta publicação, o medidor em forma de agulha é aplicável em uma variedade de fluidos. Estas publicações recentes indicam que estes medidores têm ganhado espaço em aplicações industriais principalmente devido às suas características contrutivas pois não possuem partes móveis, não provocam obstruções no fluxo e não requerem elementos secundários para realizar a medição de pressão.

Segundo Quirino (2015), medidores de vazão termais fazem uma relação entre transporte de massa e transferência de calor através do princípio da convecção forçada em um duto tendo seus sensores e elementos atuadores instalados de forma não intrusiva. Existem quatro categorias de medidores de vazão termais: anemômetros térmicos, oscilação térmica, por tempo de voo (TOF, do inglês *time of flight*) e calorimétricos.

O princípio de funcionamento dos anemômetros térmicos consiste em uma resistência elétrica, que é aquecida quando submetida a uma tensão, mas que é resfriada à medida que troca de calor com o fluido. Com base neste resfriamento, é determinada a vazão através da quantidade de calor que foi transmitida da resistência elétrica para o produto. Semelhantemente, o medidor por oscilação térmica também utiliza uma resistência elétrica, no entanto, esta resistência tem seu aquecimento controlado através de pulsos de tensão elétrica que são fornecidos de acordo com a taxa de transferência de energia térmica entre o produto que flui no interior do duto e a resistência elétrica.

Segundo Hammerschmidt (2019), os modelos que medem a vazão através do TOF funcionam monitorando o tempo de trânsito de um pulso térmico. A resistência elétrica gera um pulso de calor que após um determinado tempo é percebido por sensores de temperatura instalados a jusante do escoamento. A propagação do pulso de calor sempre dependerá das propriedades físico-químicas do fluido.

O medidor de vazão termal que utiliza a tecnologia do calorímetro, segundo Sazhin (2013), basicamente, infere a vazão monitorando mudanças do perfil de temperaturas nas imediações da resistência elétrica, região a qual permanece realizando uma constante troca de energia térmica provocada pelo escoamento de fluido. Este perfil tende a mudar de acordo com a variação da vazão sendo possível inferir o valor da vazão a partir dele.

Diversos métodos podem ser utilizados na inferência da vazão, dentre estes pode-se destacar os métodos de aprendizado de máquinas. Na literatura, há trabalhos que demonstram que a aplicação de métodos de aprendizado de máquinas em sistemas de medição de vazão é uma alternativa promissora visto que possibilita criar sistemas mais confiáveis e robustos a erros e interferências. Segundo Amaral (2019), a escolha dos algoritmos apropriados é essencial e é necessário que seja feita entre algoritmos representativos.

Dentre estes, pode-se destacar o *Gradient Boosting Regressors* (GBR). Este algoritmo funciona como um problema de otimização matemática onde o alvo é minimizar uma função de custo adicionando “modelos mais fracos” usando o procedimento do Gradiente Descendente. É composto por três elementos principais: uma função de custo a ser otimizada, um modelo fraco para fazer previsões e um modelo aditivo para adicionar um modelo fraco para minimizar a função de custo, a qual depende do problema a ser resolvido. Por exemplo, para regressão, o erro médio quadrático é habitualmente usado.

Desta forma, o objetivo deste trabalho foi desenvolver um medidor de vazão termal que fosse capaz de realizar medições de baixas vazões de água, tendo como limite inferior o valor de 0,12 m³/h (imposto pelo valor mínimo do medidor de referência) e limite superior 0,60 m³/h (imposto pela bancada experimental) em um duto com diâmetro de 22mm utilizando o princípio físico do calorímetro e métodos de aprendizado de máquinas para obter erro de fundo de escala menor que 5%, considerando os fatores de reprodutibilidade e repetibilidade.

Para alcançar estes resultados, fez-se necessário construir uma bancada automatizada, capaz de reproduzir cenários controlados de vazão para testes do protótipo, a qual foi construída viabilizando a avaliação do medidor de vazão termal com vazões entre 0,05 e 0,6 m³/h em sua fase final. Desta forma, foi possível garantir que o instrumento proposto não interfere no escoamento do fluido, faz medições com precisão e é capaz de reproduzir os mesmos valores quando submetido a sucessivas baterias de teste.

O trabalho encontra-se organizado com a seguinte estrutura: o capítulo 1, além de introduzir conceitos basilares de medição de vazão de líquidos, relaciona as principais tecnologias existentes de medição de vazão e ao final faz uma comparação entre as principais vantagens e desvantagens inerentes a cada uma delas. O capítulo 2 apresenta de forma mais detalhada as diferentes metodologias de medição de vazão por efeito térmico e demonstra teoricamente como é formado o perfil de temperaturas em um calorímetro sob a ótica da termodinâmica fazendo uma modelagem do medidor. O capítulo 3 mostra o passo a passo do projeto e construção do medidor de vazão termal não intrusivo e da bancada de testes com seus *softwares* e elementos eletroeletrônicos, apresentando também os algoritmos de aprendizado de máquinas que foram utilizados para a obtenção dos

melhores resultados. O capítulo 4 mostra os resultados obtidos com a bancada sendo utilizada em conjunto com o protótipo do medidor, avaliando o desempenho dos algoritmos de aprendizado de máquinas e a seleção do melhor modelo tendo como métrica o erro de fundo de escada e o erro fiducial como métrica auxiliar. As conclusões finais e sugestões para trabalhos futuros são listados ao final deste trabalho.

1 MEDIÇÃO DE VAZÃO

Vazão é, por definição, a quantidade volumétrica ou mássica de um fluido que escoar pela seção de uma tubulação ou canal por unidade de tempo. A medição de vazão está presente em muitas atividades do cotidiano, sendo, por isto, uma das grandezas mais medidas em diversos processos. Em processos industriais que envolvem dutos, juntamente com a pressão, é a variável de maior importância em sistemas de supervisão e controle. E por envolver escoamento de líquidos, para um melhor entendimento desta variável, faz-se necessária a aplicação de conceitos fundamentais de mecânica dos fluidos.

Um fluido simples newtoniano é uma substância que se deforma continuamente quando sujeita a uma tensão cisalhante, não importando quão pequena seja. Sabendo-se que uma força cisalhante é a componente da força que atua tangencialmente em uma superfície, quatro dimensões primárias são utilizadas nos cálculos de um sistema conforme a Tabela 1, das quais todas as outras podem ser derivadas (Stuckenbruck, 2009).

Tabela 1 - Dimensões primárias e unidades nos sistemas SI e BG

Dimensão primária	Unidade SI	Unidade BG	Fator de conversão
massa { M }	Quilograma (kg)	Slug	1 slug = 14,5939 kg
comprimento { L }	metro { m }	pé { ft }	1 ft = 0,3048 m
tempo { T }	segundo { s }	segundo { s }	1 s = 1 s
temperatura { θ }	Kelvin { K }	Rankine { °R }	1 K = 1,8 °R

Fonte: Stuckenbruck, 2009 p.2.

A partir das dimensões mencionadas, as quais são comumente expressas em unidades tanto do Sistema Internacional (*Système International d'Unités* - SI), quanto do Sistema Britânico (*British Gravitational Units* - BG), todas as outras variáveis podem ser expressadas em função de { M }, { L }, { T } e { θ }. O dimensionamento da força, por exemplo, é obtido usando a segunda lei de Newton.


$$F = ma \quad (1)$$

Desta forma, { F } = { MLT^{-2} } define a unidade de força newton (N) como,

$$1 \text{ newton} = 1 \text{ N} = 1 \text{ kg m/s}^2$$

Em um processo de medição de vazão, busca-se determinar as condições e propriedades do fluido em função da posição e do tempo. Considerando um caso hipotético onde uma substância é colocada entre duas placas paralelas horizontais e próximas, sendo a inferior fixa enquanto que uma força F é aplicada na placa superior. Havendo deslocamento da placa superior conclui-se que a substância entre as placas é um fluido. Esta experiência demonstra que um fluido em contato imediato com as placas mantém a velocidade destas e, mantidas outras quantidades constantes, a tensão cisalhante τ é diretamente proporcional ao gradiente de velocidade transversal que corresponde à taxa de deformação angular do fluido, conforme a Figura 1. A Tabela 2 lista a viscosidade e densidade de fluidos newtonianos típicos.

Figura 1 – Distribuição de velocidade entre placas paralelas



Fonte: Stuckenbruck, 2009 p.2.

$$\tau = \frac{F}{A} = \mu \frac{U}{h} = \mu \frac{\partial U}{\partial y}$$

Sendo:

μ = viscosidade dinâmica do fluido

$$[\mu] = \frac{[\tau]}{[\partial U / \partial y]} = \frac{[\text{força/área}]}{[\text{gradiente de velocidade}]} \quad (2)$$


Tabela 2 : Viscosidade e densidade de alguns fluidos (p=patm; T=20°C)

Fluido	Viscosidade Dinâmica (Pa-s)	Massa Específica (kg/m ³)
Ar	1,8 x 10 ⁻⁵	1,204
Gasolina	2,9 x 10 ⁻⁴	680
Querosene	1,82 x 10 ⁻³	810
Água	1,0 x 10 ⁻³	999
Etanol (Alcool Etílico)	1,2 x 10 ⁻³	789
Óleo SAE 30	0,26	933

Fonte: Stuckenbruck, 2009 p.3. (adaptado)

Para análise do escoamento de um fluido, é considerado o efeito da tensão cisalhante na parede do duto, a qual classificará se o perfil do escoamento é laminar ou turbulento. No regime laminar, o escoamento do fluido acontece sem haver uma mistura significativa com as partículas mais próximas. Já quando o perfil é classificado como turbulento, o escoamento varia de maneira acentuada fazendo com que a velocidade do fluido apresente alterações ao longo do trajeto. A fase de mudança entre o perfil laminar para o turbulento é chamada regime de transição.

Figura 2 – Regimes de Escoamento



Fonte: Silva, 2017, p.25. (adaptado)

A medição deste efeito sobre o escoamento é feita com base no número de Reynolds, que é a divisão entre força de inércia e força em função da viscosidade do fluido (Mattos, 1998).

$$Re = \frac{D V \rho}{\mu} \quad (3)$$

Sendo,

Re = número de Reynolds

D = diâmetro interno da tubulação

V = velocidade média do escoamento

ρ = massa específica

μ = viscosidade

Conhecendo os valores V , D e μ é possível calcular o número de Reynolds que classificará o tipo de escoamento em dutos circulares da seguinte forma:

$Re < 2300$ Regime laminar

$Re > 4000$ Regime turbulento

Em dutos nota-se uma faixa crítica entre $Re = 2300$ e $Re = 4000$ quando ocorre o regime de transição. Entretanto este fato não constitui em problemas tendo em vista que, na prática industrial, o regime é sempre turbulento. Este só é considerado laminar quando a velocidade de escoamento é muito baixa ou quando o fluido é muito viscoso.

1.1 Medidores de Vazão

Várias tecnologias são empregadas para medir vazão. Os medidores utilizados são tipificados como intrusivos ou não intrusivos, bem como invasivos ou não-invasivos de acordo com a perturbação que o elemento transdutor introduz no escoamento. Transdutores intrusivos são modelos que interagem físico e quimicamente com o processo em que se efetua a medida. Já os modelos invasivos são aqueles que além de apresentarem interação físico-química com o processo em que se efetua a medida, também têm contato com o processo (Oliveira, 2010).

Nos medidores intrusivos e invasivos, conforme a Figura 3, o elemento transdutor fica em contato com o escoamento tendo como desvantagem serem um obstáculo ao fluido, o que gera uma perda de carga. Além disso, pode ocorrer acúmulo de materiais e contaminação do escoamento. No caso dos medidores com tecnologia não-intrusiva, não ocorre o contato entre o fluido e o instrumento de medição. Por não provocar obstrução na vazão, este modelo tem a vantagem de não gerar perda de carga, além de ser de mais fácil instalação. Estas vantagens fazem os medidores com tecnologias não intrusivas ganharem mais notoriedade.

Figura 3 - Características das medições

	INVASIVA	NÃO-INVASIVA
INTRUSIVA		
NÃO-INTRUSIVA		

Fonte: Asher, 1997.


1.1.1 Medidores Deprimogênios

Dentre os medidores com características intrusivas existem os modelos deprimogênios. São os mais antigos e os mais amplamente utilizados. Empregam a correlação entre a queda de pressão intencionalmente provocada por um obstáculo à passagem de um fluido com a geometria conhecida inserida dentro da tubulação na qual se pretende medir a vazão (Correia, 2009).

O princípio fundamental dos medidores do tipo deprimogênio é colocar um obstáculo ao escoamento do fluido, reduzindo a área de maneira que haja variação na pressão do fluido

confinado. Conforme a Figura 4, a medida do diferencial de pressão (ΔP) entre o ponto 1 a montante e o ponto 2 a jusante do obstáculo torna possível estimar a vazão.

Figura 4 – Escoamento através de uma redução de área



Fonte: Cassiolato, 2008 p.4.

Neste sistema, a vazão para um mesmo fluido de propriedades bem definidas é dada pela equação 4:

$$Q = K\sqrt{\Delta P} \quad (4)$$

Sendo,

Q = vazão

K = constante de proporcionalidade

ΔP = diferencial de pressão entre os pontos 1 e 2 da Figura 4


Os exemplos mais notáveis deste tipo de instrumento são as placas de orifício (Figura 5), o tubo de Venturi (Figura 6) e Anubar (Figura 7).

Figura 5 – Modelos de placas de orifício



Fonte: <<https://www.jcn.ind.br/placa-orificio>>
 acessado em: 20/04/2020

Figura 6 – Esquemático de um tubo de Venturi



Fonte: adaptado de < <http://www.presys.com.br/blog/vazao/> > acessado em: 20/04/2020

Figura 7 – Modelos de Medidores Annubar do fabricante Emerson



Fonte: adaptado de < <https://www.emerson.com/pt-br/automation/measurement-instrumentation/pressure-measurement/differential-pressure-dp-flow/about-annubar-pitot-tube-technology> > acessado em: 20/04/2020

Embora sejam amplamente utilizados, os medidores deprimogênicos têm as seguintes desvantagens:


- Provocam uma perda de carga adicional na linha causando um dispêndio a mais de energia no bombeamento;

- Necessidade de trecho reto e condicionado a montante e jusante para retificação dos componentes rotacionais do perfil de velocidade;
- Necessidade de inspeção periódica devido à possibilidade de erosão pelo fluido, o qual tende a alterar os cantos vivos na geometria do obstáculo utilizado;
- A rangeabilidade limitada, uma vez que esta é definida pela raiz quadrada do transmissor de pressão diferencial (PDT) a ele conectado;
- Em geral, a menor exatidão da medição, que é feita de forma indireta, levando à necessidade de compensar os parâmetros que fazem variar a constante K como temperatura, pressão, densidade e, em segundo plano, a viscosidade do fluido.

1.1.2 Tipo VORTEX

Os medidores do tipo VORTEX, também pertencentes à categoria dos deprimogênicos, conforme a Figura 8, operam pelo princípio da determinação do padrão do sinal de pressão diferencial (esteira de von Karman) criado por um vórtice decorrente de um obstáculo no fluxo. O princípio de funcionamento é a instalação de um obstáculo em um trecho reto da tubulação, de maneira que se crie uma perturbação no escoamento. Tal perturbação são vórtices periódicos sendo que a frequência com que estes vórtices ocorrem é caracterizada pelo número de Strouhal e se relaciona com a vazão (Albertazzi, 2008). Sua rangeabilidade é menor ou igual a 10, apresentando uma pressão diferencial de 60 a 80% ao equivalente a uma placa de orifício.

Figura 8 – Modelo de Medidor do Tipo VORTEX



Fonte: adaptado de < <https://www.shimizu.com.br/artigo/medicoes-de-vazao-na-industria> >

Acessado em: 20/04/2020

A frequência dos vórtices é dada pela seguinte equação, onde S é o número adimensional de Strouhal:

$$f = \frac{S \cdot v}{d} \quad (5)$$

1.1.3 Deslocamento Positivo

Os medidores de deslocamento positivo têm como principal característica as partes internas girantes que interceptam a passagem do fluido que cedem a elas energia e as faz girar. Os denominados PDM (*Positive Displacement Meter*) possuem internos com diferentes arranjos geométricos definindo câmaras que aprisionam pequenos volumes do fluido os quais ativam a rotação do dispositivo na saída do medidor ao serem liberados.

Conforme a Figura 9, uma volta de 360° corresponde a um determinado volume conhecido que passou pelo medidor e, assim, a velocidade de rotação em voltas por unidade de tempo multiplicada por este volume define a vazão. O nome “deslocamento positivo” advém deste fato. Dentre os PDM mais conhecidos empregados em tubulações, estão os do tipo tambor com palhetas rotativas, lóbulos, engrenagem e diafragma.

Figura 9 – Estágios de um Medidor do Tipo Deslocamento Positivo




Fonte: <<https://br.omega.com/artigos-tecnicos/medidor-de-vazao-por-deslocamento-positivo>>
acessado em 20/04/2020

1.1.4 Turbinas

As turbinas, conforme a Figura 10, possuem internamente rotores dotados de paletas paralelas arranjadas com um determinado ângulo de ataque ao fluido que entra no medidor.

Figura 10 – Medidor do Tipo Turbina



Fonte: White, 2002

Estes medidores, pela classe de exatidão que exibem, são comumente empregados nas operações de transferência de custódia, as quais envolvem venda de produto. As turbinas são as mais utilizadas pela sua faixa de operação, baixo custo e porte físico reduzido, tanto para gás quanto para líquidos.

1.1.5 Ultrassônicos

Medidores de vazão ultrassônicos, representados na Figura 11, inferem a vazão volumétrica por meio da medição da velocidade do escoamento do fluido, principalmente pelo princípio do tempo de trânsito. Neste instrumento, um pulso de ultrassom é emitido no sentido a favor do fluxo e outro no sentido contrário sob a chamada “corda de medição” formada pelo caminho entre dois sensores. A velocidade do escoamento é calculada tendo como base a diferença entre os tempos de resposta dos pulsos. Podem ser do tipo “Clamp on”, onde os cabeçotes dos transdutores de ultrassom são instalados externamente ao tubo e neles fixados por uma braçadeira, ou do tipo molhados, onde os transdutores se assentam diretamente em contato com o fluxo, ou em carretéis de câmaras estanques, dotadas de “lentes” metálicas para transmissão do pulso ultrassônico (Correia, 2009).

Os medidores ultrassônicos apresentam limitações, como:

- Necessidade de condicionamento do fluxo através de trechos retos à montante e à jusante do medidor e montagem rigorosa quanto ao alinhamento, para evitarem-se componentes rotacionais no escoamento
- Sensibilidade, quando aplicados em líquidos, a problemas que levem à descontinuidade das características físicas do fluido e que impliquem em refração/reflexão do pulso ultrassônico na superfície ou região de transição dessas propriedades que, a depender da sua severidade, levam à perda do sinal no instrumento. As causas mais recorrentes são: sólidos em suspensão, bolhas de gases e presença de líquidos de outra natureza no seio do fluido medido, como água de formação em petróleo.
- Sensibilidade ao número de Reynolds caracterizado no escoamento, sobretudo quando é muito alta a viscosidade do produto. Quanto maior a viscosidade, maior absorção pelo fluido da energia ultrassônica, o que limita o diâmetro máximo do medidor.

Dentre as suas vantagens estão:

- Não têm partes móveis sujeitas a desgastes mecânicos alterando sua curva;
- Apresentam grande faixa de medição;
- Alta estabilidade e grandes intervalos entre calibrações;

- Possuem alto tempo médio entre falhas;
- Fácil instalação no caso dos modelos “Clamp on”;
- Têm a opção de aumentar o número de canais;

Figura 11 –Medidor do Tipo Ultrassônico




Fonte: <<https://www.directindustry.com/prod/ge-measurement-control/product-7233-1382069.html>> acessado em 20/04/2020

1.1.6 Tipo Coriolis (Mássicos)

Medidores de vazão do tipo Coriolis, representados na Figura 12, adotam o princípio da aceleração de Coriolis. Dado o princípio de operação que empregam, não são medidores volumétricos, mas de vazão mássica. O processo de medição é realizado por eletroímãs que detectam os movimentos oscilatórios gerados pela torção de tubos secundários, quando percorridos pelo fluido. A defasagem destas torções é usada para calcular a vazão.

Figura 12 –Medidor do Tipo Coriolis




Fonte: Adaptado de <https://docplayer.com.br/23613425-Instrumentos-de-vazao-adrielle-c-santana.html> acessado em 20/04/2020

1.1.7 Eletromagnéticos

A medição de vazão por efeito eletromagnético é amplamente utilizada por não ser sensível à densidade do fluido. Medidores com esta tecnologia são muito utilizados para medição de produtos corrosivos e fluidos com partículas suspensas. Sua principal vantagem é não apresentar perda de carga. No entanto, tem como restrições o fato do fluido precisar ser eletricamente condutivo e fluidos com propriedades magnéticas provocam erro na medição.


Seu princípio de funcionamento consiste num campo magnético (B) fixo ou variável no tempo atuando no sentido perpendicular a um duto condutor por onde escoo o fluido e uma tensão elétrica, $e(t)$ diretamente proporcional à velocidade do fluxo, sendo induzida nos eletrodos (E) e (E'), seguindo a lei de Faraday (Colantonio, 2007) conforme as Figuras 13 e 14.

Figura 13 – Medidor de vazão eletromagnético



Fonte: Colantonio, 2007 p. 20.

Figura 14 – Funcionamento de um medidor de vazão eletromagnético



Fonte: Colantonio, 2007 p. 20.

1.1.8 Vibração Induzida pelo Fluxo

A medição de vazão feita por modelos que usam o princípio da Vibração Induzida pelo Fluxo (FIV) baseia-se na coleta das vibrações provocadas no duto como consequência do escoamento do fluido, conforme registra a Figura 15. De acordo com Evans (2004), a Primeira e a Segunda Lei de Newton possibilitam afirmar que, através da aceleração que um fluido transmite para outro corpo, a massa desse fluido pode ser medida.

Na montagem do medidor, dois acelerômetros piezoelétricos de sensibilidades diferentes são posicionados no duto, os quais leem os dados de vibração da superfície.

Figura 15 – Medidor por FIV



Fonte: Medeiros et al, 2015 p. 1404.

A amplitude das vibrações induzidas pelo fluido fornece indicadores que se relacionam com a vazão. Em procedimentos experimentais, o método apresenta uma incerteza de 5% da vazão medida. (EVANS, 2004).


1.1.9 Termais

A medição de vazão termal é um método comum de medição de vazão em escoamentos tanto laminares quanto turbulentos. Faz uso da relação de transferência de energia térmica de um elemento aquecedor para o fluido em regime de escoamento. Com a temperatura mantendo-se constante e somente a velocidade do fluido variando significativamente, a variação de energia térmica detectada pode ser representada como uma função da variação da vazão.

A utilização deste princípio de medição por efeito térmico foi proposta pela primeira vez por LV King em 1914, quando postulou a Lei de King através de um experimento imergindo cilindros aquecidos em um fluido com escoamento.

Com base neste conceito, foi proposto um número considerável de princípios de medição que variam dependendo do arranjo entre as medições de temperatura (Comte-Bellot, 1976). A Figura 16 mostra um anemômetro típico tal como utilizado na experiência de LV King.

Figura 16 – Experiência de LV King



Fonte: Adaptado de Comte-Bellot, 1976.

Esta técnica de medição se tornou popular pelo fato de utilizar sondas que ocupam pouco espaço e por oferecer a possibilidade de instalar os dispositivos térmicos na parte externa do duto, sendo possível mitigar as interferências geradas pelo instrumento no escoamento, tais como perdas de velocidade e pressão, bem como proteger os sensores e atuadores de possíveis danos ocasionados pelo contato com o fluido.

É um método promissor tendo em vista que apresenta resultados com baixa incerteza da ordem de 0,2% de fundo de escala, sendo competitivo em relação a outros métodos de medição de vazão (Rachalski, 2006). No entanto, fatos como depender das propriedades térmicas do fluido assim como do duto e ser afetado por partículas suspensas no escoamento trazem limitações.

1.2 Comparação entre as Tecnologias de Medição de Vazão

Uma comparação entre as tecnologias de medição apresentadas neste capítulo é feita na Tabela 3 e evidencia as vantagens da medição de vazão termal como uma excelente alternativa em relação às outras. No capítulo seguinte esta tecnologia será estudada mais detalhadamente.

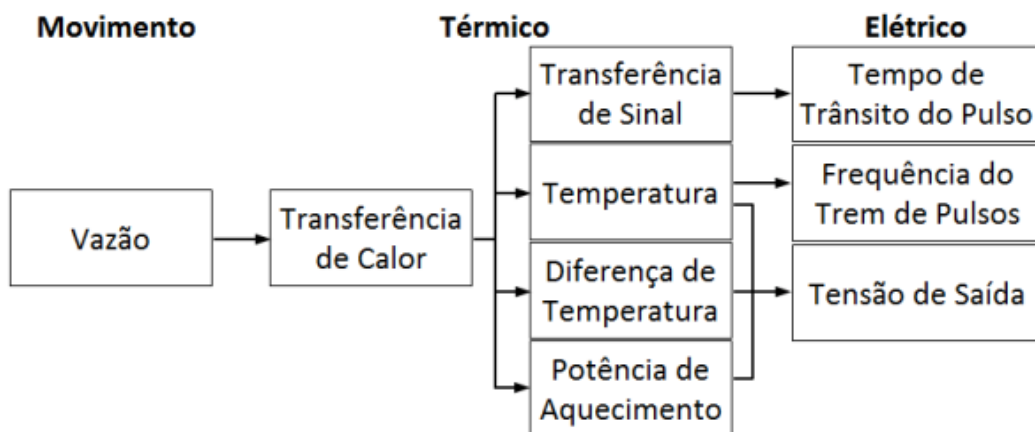
Tabela 3 : Tabela comparativa dos principais medidores de vazão usados em tubulações

Modelo	Vantagem	Desvantagem
Deprimogênitos	Baixo custo Construção simples Manutenção e troca simples	Alta perda de carga Baixa rangeabilidade Necessidade de inspeção periódica
Vortex	Saída linear Alta precisão Construção simples	Alto custo Intrusivo Exige longos trechos retos
Deslocamento Positivo	Alta precisão Independente das propriedades do fluido	Alta perda de carga Alto custo de fabricação Exige ausência de contaminantes
Ultrassônicos	Sem perda de carga Existem modelos portáteis não-invasivos Vários diâmetros	Alto custo Limitação para pequenos diâmetros Sensível a particulados
Coriolis	Alta precisão Admite particulados Baixa perda de carga	Alto custo Sensível à vibração externa Intrusivo
Eletromagnético	Bom desempenho em baixas vazões Baixa perda de carga	O líquido deve ter condutividade mínima de 200 μ S/m Alto custo para pequenos diâmetros
Vibração Induzida pelo Fluxo	Não intrusivo Ampla range de medição	Suscetibilidade a interferências eletromagnéticas Suscetibilidade a vibrações da planta de processo
Termal	Baixo Custo Ampla range de medição Baixa perda de carga	Depende das propriedades térmicas do fluido e do duto.

2 TECNOLOGIAS TERMAIS DE MEDIÇÃO DE VAZÃO

A tecnologia termal de medição de vazão pode ser representada sob a forma de um fluxograma onde o valor da vazão, que é uma grandeza mecânica, é inferido utilizando o efeito térmico combinando um dispositivo gerador de calor e sensores captadores de temperatura, os quais têm estas variáveis convertidas em sinais elétricos pelos elementos secundários, conforme a Figura 17.

Figura 17 – Aquisição e processamento dos dados para medição de vazão termal



Fonte: adaptado de NGUYEN, 1999.

Este modelo possibilita diversos arranjos entre o elemento aquecedor e os sensores de temperatura, inclusive a possibilidade de utilizar esta tecnologia de forma não intrusiva. Dependendo do princípio de medição utilizado, os medidores de vazão termais podem ser categorizados como anemômetro térmico (Zichuanet al., 2013), por tempo de trânsito (Engelien et al., 2013), por convecção forçada (Oliveira, 2010), por oscilação térmica (Smith et al., 1981) e calorímetro (Quirino, 2015).

2.1 Anemômetro Térmico


Anemômetros são instrumentos utilizados para medir a velocidade de um fluido que podem ter diversas características construtivas e operacionais. A anemometria térmica está entre as tecnologias de medição de vazão mais comuns, que consiste em um elemento aquecido por uma corrente elétrica ser imerso no fluido e ser resfriado pela ação de troca de calor com o fluido em movimento. Assim, é possível inferir a vazão por meio da quantidade de calor transferida do elemento aquecido para o fluido (Quirino et al, 2014)

Anemômetros térmicos são indicados para medir fluidos em baixas velocidades. O funcionamento deste modelo de medidor é baseado na medição do diferencial de temperatura entre o elemento gerador de calor e o fluido. O valor deste diferencial é correlacionado à velocidade do fluido. Esta tecnologia permite uma diversidade de aplicações, sendo uma delas utilizar a superfície do duto para as interações térmicas em vez de utilizar um fio quente (Feuermann, 1992; Oliveira, 2010).

A aplicação deste princípio de medição, de forma não-intrusiva, utiliza um elemento aquecedor Q acoplado ao duto e dois sensores de temperatura T_1 e T_2 , sendo T_2 instalado junto ao aquecedor e T_1 a montante do trecho aquecido. Pode-se optar pela instalação do T_1 a jusante do aquecedor, mas neste caso haverá influência da temperatura que foi transportada pelo fluido. Esta configuração possibilita utilizar dois métodos para medir a vazão.

Um método é por diferença de temperatura constante, no qual se monitora a variação da potência em Q para manter a diferença de temperatura entre T_1 e T_2 constante. O outro método é por potência constante, no qual se monitora a variação do diferencial de temperatura entre T_1 e T_2 mantendo-se a potência em Q constante. O arranjo típico é representado na Figura 18.

Figura 18 – Arranjo típico de um anemômetro térmico



Por serem baseados no princípio da troca térmica entre o fluido e o medidor, estes medidores medem a vazão mássica (Oliveira, 2010) regidos pela Equação 6:

$$\dot{m} = \frac{\dot{Q}}{C_p \times \Delta T} \quad (6)$$

Sendo:

\dot{m} = Vazão mássica do fluido em kg/s;

\dot{Q} = Taxa de calor fornecida pelo aquecedor ao fluido em J/s;


C_p = Calor específico volumétrico do fluido em J/m³K a uma pressão constante;

ΔT = Diferença de temperatura entre o fluido e o medidor em K;

2.2 Tempo de Trânsito

Este método determina a vazão do fluido a partir da medida do tempo que o sensor T leva para detectar o pulso de calor emitido pelo aquecedor Q. A vazão no interior do duto afetará diretamente a transferência de calor pela superfície, sendo o tempo de trânsito desta energia térmica diretamente relacionado à velocidade do escoamento conforme a Figura 9.


Figura 19 – Arranjo de um anemômetro térmico por tempo de trânsito



2.3 Convecção Forçada

Esta tecnologia de medição, conforme a Figura 20, utiliza uma termorresistência para medir a temperatura do fluido enquanto que um outro sensor é aquecido de forma que se mantenha um diferencial constante de temperatura entre o fluido e a região do sensor aquecida. À medida que houver incremento na vazão, haverá maior volume passando pela região o que acarretará em uma maior troca de calor com a parte do sensor que está aquecida. A diminuição de calor no elemento aquecido é proporcional à vazão (Rachalski, 2006) e, quando medida pela termorresistência possibilita a medição do fluxo.

Figura 20 – Medidor de vazão por convecção forçada



Fonte: Oliveira, 2010 p. 39.

Neste medidor, a vazão mássica pode ser calculada através da seguinte equação (Oliveira, 2010):

$$\dot{m} = \left[\frac{1}{B} \left(\frac{\dot{Q}}{\Delta T} - A \right) \right] \quad (7)$$

Sendo:

\dot{m} = Vazão mássica do fluido em kg/s;

\dot{Q} = Taxa de calor fornecida pelo aquecedor ao fluido em J/s;

ΔT = Diferença de temperatura entre o fluido e o medidor em K;

A e B = constantes da equação de King

2.4 Oscilação Térmica

Este modelo, conforme a Figura 21, utiliza um elemento aquecedor e um elemento sensor acoplado ao duto. Quando o pulso de aquecimento é aplicado, ele modifica a temperatura do sensor. A métrica utilizada é um registro do tempo necessário para o resfriamento do sensor até um valor previamente ajustado. Quando o valor é atingido, um novo pulso de calor é emitido e assim, ciclicamente, o processo se repete gerando um comportamento oscilatório da temperatura, bem como uma sequência de pulsos no aquecedor. Através da frequência dos pulsos é possível determinar a vazão (Briggs-Smith et al, 1981), conforme a Figura 22.

Figura 21 – Medidor de vazão por oscilação térmica


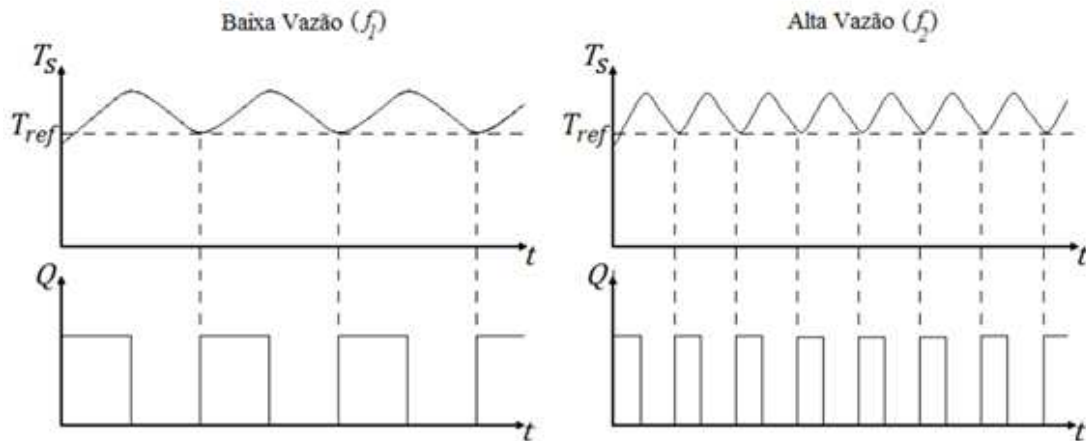


Figura 22 – Gráfico de oscilação térmica



Fonte: Briggs-Smith et al, 1981.

2.5 Calorímetro

A tecnologia termal de medição de vazão conhecida como calorímetro representada na Figura 23 utiliza técnicas combinadas de fluidodinâmica e termodinâmica para medir escoamentos internos e é o objetivo principal deste trabalho. Faz-se necessário, portanto, conhecer o comportamento e os fenômenos físicos envolvidos desta modalidade de medição de vazão, especialmente a transferência de calor.

Segundo Hoera (2015), calorímetros usam o perfil de temperatura gerado a partir de um elemento aquecedor instalado em um canal cheio de fluido para quantificar a vazão. Em condições estáticas, uma temperatura simétrica é observada no perfil onde o valor máximo fica no elemento de aquecimento. Quando é aplicado um fluxo, conforme a Figura 24, o perfil de temperatura fica assimétrico e a posição da temperatura máxima muda na direção do fluxo. Esta assimetria do perfil é normalmente avaliada com um ou mais sensores de temperatura a montante e a jusante do elemento aquecedor e podem ser correlacionados com a vazão no canal.

Figura 23 – Calorímetro Típico





Figura 24 – Perfis típicos do gradiente de temperatura



Nesta aplicação, a temperatura do fluido deve ser menor que a do duto aquecido. Desta forma, a alteração no perfil acontece por haver diminuição da temperatura do duto a montante do aquecedor e o consequente aumento de temperatura do fluido. À medida que o fluido aquecido se move no trecho a jusante do aquecedor, ocorre a troca térmica com a superfície de forma mais gradual.

De forma análoga ao anemômetro térmico, dois métodos podem ser utilizados para o controle do aquecedor: manutenção da temperatura constante em algum ponto do perfil enquanto o restante do perfil se modifica de acordo com a vazão ou uma potência constante é aplicada no aquecedor e todo o perfil é modificado de acordo com a vazão.

2.6 Simulação através do COMSOL

É importante nesta parte do estudo esclarecer os efeitos termodinâmicos que ocorrem neste tipo de tecnologia de medição de vazão, tendo em vista que o objetivo é a construção do protótipo. Faz-se necessário um entendimento do modelo físico do calorímetro para que haja uma melhor compreensão dos efeitos físicos envolvidos, principalmente a transferência de calor que é, por definição, energia em trânsito promovida por uma diferença de temperatura entre diferentes regiões do espaço.

Como o modelo proposto tem como metodologia a medição térmica, esta deve ser compreendida e realizada de forma eficiente e precisa. Isto deve-se ao fato de que processos de medição que possuem grandezas intermediárias têm maior possibilidade de propagação de erros. Para compreender melhor os fenômenos físicos que ocorrem no calorímetro, foi realizada a modelagem do sensor proposto neste trabalho através do ambiente de modelamento COMSOL Multiphysics. O ambiente COMSOL permite fazer a análise de elementos finitos através da divisão em partições destes elementos aplicando as leis físicas de movimento e

transferência de calor através de métodos numéricos. Módulos complementares desta ferramenta também permitem expandir suas funcionalidades e aplicar conceitos de mecânica dos fluidos, mecânica estrutural bem como transferência de calor.

Durante a análise do escoamento, devido à convecção, o COMSOL o definiu pela equação de Navier-Stokes, representada pela equação 8, e em respectivo a equação de continuidade, dada pela equação 9 (COMSOL, 2017).

$$\rho(\mathbf{u} \cdot \nabla)\mathbf{u} = \nabla \cdot [-p\mathbf{I} + \mu(\nabla\mathbf{u} + (\nabla\mathbf{u})^T)] + \mathbf{F} \quad (8)$$

$$\nabla \cdot (\mathbf{u}) = 0 \quad (9)$$

A massa específica ρ e velocidade \mathbf{u} do fluido compõem o primeiro termo da equação de Navier-Stokes que são correspondentes às forças inerciais. O segundo termo é dividido em duas partes no divergente, em que p são as forças relacionadas a pressão somadas as forças viscosas, sendo então o parâmetro μ a viscosidade dinâmica do fluido que ao ser representada em dependência da temperatura é escrita como η . F é a força externa (COMSOL, 2017).

O COMSOL fornece um relatório com as equações utilizadas para análise computacional da transferência de calor, na forma de condução e convecção, assim como os parâmetros necessários à simulação. O equacionamento da simulação de transferência de calor, pelo programa, ocorre a partir das equações de difusão do calor em regime estacionário representada pela equação 10, e pela lei de condução de Fourier, apresentadas na equação 11 (INCROPERA, 2011). O primeiro termo da equação 10 representa o transiente, mas é mantido mesmo na análise de regime permanente do sistema, por ocasião da convecção, que considera variação da posição de massa no tempo.

$$\rho C_p \mathbf{u} \cdot \nabla T + \nabla \cdot \mathbf{q} = \mathbf{Q} \quad (10)$$

$$\mathbf{q} = -k\nabla T \quad (11)$$

Sendo:

- ρ a massa específica;
- u a velocidade de deslocamento;
- c_p o calor específico do fluido;
- ∇T o gradiente de temperatura que ocorre pelo deslocamento de fluido;
- $\nabla \cdot \mathbf{q}$ gradiente de calor

O segundo termo da equação 10 é o gradiente de calor, se relaciona diretamente com a equação 11, cujo ∇T é o gradiente de temperatura que ocorre por condução e k é a


condutividade térmica da condução. Finalmente o termo Q é o fornecimento de calor ao sistema (COMSOL, 2018).

Para definir as condições de transporte de massa e transferência de calor, o primeiro elemento a ser analisado é o fluido que circulará no sistema que no caso deste trabalho será a água em fase líquida. Dentre as suas principais características, é necessário destacar que se trata de um fluido incompressível devido ao fato de suas moléculas terem pouca distância entre si resultando em uma alta densidade. Tendo em vista que a troca de calor, que ocorrerá no processo, é função da vazão de água no interior do duto, é importante compreender como será o comportamento termodinâmico deste fluido especialmente o calor específico e a condutividade térmica.

O calor específico (C_p) de uma substância é a quantidade de energia que deve ser fornecida para que uma determinada porção desta substância tenha sua temperatura elevada em uma determinada parcela. Já a condutividade térmica (k) é a medida da capacidade de condução de energia térmica que cada material tem. No caso deste projeto, têm-se um duto de cobre de 240mm, com diâmetro interno de 22mm e espessura de 1mm aquecido na região central provocando um gradiente de temperatura ao longo de sua superfície. Desta forma, tanto o calor específico da água quanto a condutividade térmica terão seus valores regidos por equações obtidas através do COMSOL, às quais são aproximações de uma série de Taylor, tal como pode ser observado a seguir nas Figuras 25 e 26:

$$c_{p,água}(T) = 12010.15 - 80.41 T + 0.31 T^2 - 5.38 \cdot 10^{-4} T^3 + 3.62 \cdot 10^{-7} T^4 \quad (12)$$

Figura 25 – Variação do $c_{p,água}$




Desta forma, nesta modelagem, a porção de água que passar pelo trecho do duto aquecido com uma temperatura entre 50 a 70°C (323,15 a 343,15 K), terá um calor específico aproximado igual a:

$$c_{p,água} \cong 4200 \frac{J}{kg \cdot K}$$

De forma semelhante, a mesma análise é feita para a condutividade térmica:

$$k_{água}(T) = -0.87 + 8.95 \cdot 10^{-3} T - 1.58 \cdot 10^{-5} T^2 + 7.97 \cdot 10^{-9} T^3 \quad (13)$$

Figura 26 – Variação do $k_{água}$



Simplifica-se a interpretação que se faz da simulação utilizando a condutividade térmica média da água ($\bar{k}_{água}$).

$$\bar{k}_{água} \cong 0.64 \frac{W}{m \cdot K}$$

A condutividade térmica da água não é aplicada diretamente pelo COMSOL. Na simulação de convecção utiliza-se coeficiente convectivo (h), que mede a quantidade de calor transferida por unidade de área. Isso se deve ao fato de o gradiente de temperaturas pela convecção (∇T_S) ser calculado pela lei de resfriamento de Newton, que relaciona a densidade de fluxo de energia térmica (q), em uma área uniforme (A_{conv}) de modo proporcional à diferença de temperatura média de mistura do fluido (T_m) a partir de uma superfície de referência (T_S), apresentada na equação 13.

$$q = hA_{conv}(T_S - T_m) \quad (13)$$

No caso específico, pode-se calcular, a critério de interpretação, o valor médio de \bar{h} válido para um número de Reynolds menor que 2500, a partir da condutividade térmica média da água $\bar{k}_{\text{água}}$.


$$h = 3.66 \frac{k_{\text{água}}}{D_i}, Re < 2500 \text{ (Laminar)}$$

$$h \cong 106 \frac{W}{m^2 \cdot K}$$

A massa específica da água ρ é modificada em função da temperatura, conforme visto na Figura 27, pois há variação de volume da água por expansão ou contração, mantendo-se a quantidade de massa constante. A expressão é aproximada por série de Taylor em:

$$\rho(T) = 838.47 + 1.40 T - 3.01 \cdot 10^{-3} T^2 + 3.72 \cdot 10^{-7} T^3 \quad (14)$$

Figura 27 – Variação do $\rho_{\text{água}}$




As temperaturas utilizadas neste trabalho caracterizam a densidade da água em um valor de:

$$\rho = 990 \frac{kg}{m^3}$$

A viscosidade dinâmica dependente da temperatura η , conforme a Figura 28, necessária para cálculo da velocidade do fluido, que na simulação do COMSOL é dada por:

$$\eta(T) = 1.38 - 0.02 T + 1.36 \cdot 10^{-4} T^2 - 4.64 \cdot 10^{-7} T^3 + 8.90 \cdot 10^{-10} T^4 - 9.08 \cdot 10^{-13} T^5 + 3.84 \cdot 10^{-16} T^6 \quad (15)$$

Figura 28 – Variação do $\eta_{\text{água}}$



Analisa-se a viscosidade dinâmica no intervalo de temperaturas de interesse para o valor aproximado de:

$$\eta = 3 \cdot 10^{-4} \frac{s \cdot Pa}{K}$$

A partir deste ponto, para fazer a simulação, o sistema é alimentado com os parâmetros geométricos do projeto do calorímetro. Os parâmetros iniciais do duto, nesta fase de projeto, foram:

- $L = 0,24$ m;
- $D_i = 0,022$ m;
- $D_e = 0,024$ m;

Sendo:

- L = comprimento;
- D_i = diâmetro interno;
- D_e = diâmetro externo;

Estes parâmetros geométricos iniciais, em especial o comprimento do duto, são fundamentais para realizar o cálculo dos outros parâmetros a partir desta fase, mesmo que o comprimento não seja utilizado em toda sua extensão para medição das temperaturas, a saber:

$$P_i = \pi D_i \cong 6,9 \cdot 10^{-2} \text{ m}$$

$$A_s = \pi D_e \cdot L = 1,8 \cdot 10^{-2} \text{ m}^2$$

$$A_c = \pi \left(\left(\frac{D_e}{2} \right)^2 - \left(\frac{D_i}{2} \right)^2 \right) = 7,2 \cdot 10^{-5} \text{ m}^2$$

Sendo:

- P_i = perímetro interno;
- A_s = área superficial;
- A_c = área de condução;

Sabendo-se que o duto é feito de cobre, é necessário alimentar o sistema também com os parâmetros térmicos deste material, tendo em vista que esta fase é fundamental para a análise da condução, a saber o calor específico do cobre ($c_{p,cu}$), a condutividade do cobre (k_{cu}) e a massa específica do cobre (ρ_{cu}), que são determinados por:

$$c_{p,cu} = 385 \frac{J}{kg \cdot K}$$

$$k_{cu} = 4000 \frac{W}{m \cdot K}$$


$$\rho_{cu} = 8960 \frac{kg}{m^3}$$

Foi idealizada uma geometria retangular a ser revolucionada sobre um dos lados do retângulo representando o calorímetro cilíndrico. Fazendo a simulação em duas dimensões, pode-se conceber o calorímetro como um retângulo com as faces superior e inferior isoladas, pois a dimensão de revolução não possui variação alguma no fluxo térmico. O ponto de aquecimento foi calculado de maneira que se encontrasse no meio da geometria. A princípio, o calor do aquecedor é transferido pelo duto no eixo transversal da vazão e posteriormente de forma radial por convecção.

Desta forma, o modelo obtido se propõe a descrever um calorímetro num duto de cobre cujo elemento aquecedor se mantém a uma temperatura constante de 70°C e cuja vazão varia de 0,05 a 0,7m³/h com temperatura monitorada a montante e a jusante do elemento aquecedor. Na condição de vazão máxima, o número de Reynolds calculado é 11,2 o que indica que o regime é sempre laminar.


Aplicados todos os parâmetros e formatando a geometria no programa, a simulação foi realizada pelo método dos elementos finitos. Aplicando uma taxa de tolerância do erro para a simulação da ordem de 10^{-3} , é possível observar na Figura 29 que a simulação converge para um erro da ordem de 10^{-4} tanto no deslocamento mássico, quanto no fluxo de calor.

Figura 29 – Curva de convergência do modelo em elementos finitos



A partir deste modelo, é possível reconhecer a distribuição de temperaturas na superfície, conforme mostra a figura 30.

Figura 30 – Distribuição da temperatura



A partir do modelo obtido, foi possível gerar a Figura 31 para obter uma prévia dos resultados esperados pelo experimento, assim como simular como será o perfil da temperatura em função da vazão na Figura 32.

Figura 31 – Distribuição teórica da temperatura na superfície do tubo (°C)






Figura 32 – Perfil de temperatura em função da vazão simulado no COMSOL



Um corte transversal feito na figura 32, limitando os valores de distância somente às posições onde os sensores de temperatura denominados A, B, C, D, E e F serão instalados, possibilita prever como será o comportamento do protótipo em cada intervalo de vazão, tal como demonstrado na Figura 33 cuja legenda mostra apenas as vazões mínima, média e máxima.

Figura 33 – Perfil de temperatura simulado no COMSOL com representação dos sensores instalados




O COMSOL também permitiu modelar o perfil de distribuição teórica de velocidade do fluido dentro do duto. Aplicando os resultados do estudo de viscosidade dinâmica, bem como também os conceitos vistos no capítulo 1 no qual demonstrou-se que a tensão cisalhante τ é diretamente proporcional ao gradiente de velocidade transversal que corresponde à taxa de deformação angular do fluido, foi possível também simular a distribuição da velocidade do fluido no interior do calorímetro conforme as Figuras 34 e 35.

Figura 34 – Distribuição teórica de velocidade no fluido (m/s)



Figura 35 – Perfil teórico da velocidade do fluido



Tendo como ponto de partida todo este arcabouço teórico, a proposta do capítulo seguinte é construir um medidor de vazão termal capaz de reproduzir, de maneira empírica, os resultados previstos considerando o dimensionamento obtido neste capítulo.

3 CONSTRUÇÃO DO MEDIDOR E DA BANCADA DE TESTES

A construção de um modelo físico de um medidor inteligente por efeito termal, não intrusivo e capaz de inferir vazão com erro de fundo de escala menor que 5% é o cerne deste trabalho. O medidor proposto utiliza a técnica do perfil de temperaturas e opera tendo como fluido a água. Foi necessário construir não só o medidor, mas toda a planta de processo capaz de gerar vazão controlada e armazenar a água em temperatura constante, bem como criar um ambiente supervisor capaz de monitorar, comandar e adquirir todos os dados de vazão e temperatura da planta. Todo este aparato experimental encontra-se no Laboratório de Redes Industriais e Sistemas de Automação (LARISA-UERJ).


3.1 Construção do protótipo

Para se obter o melhor efeito térmico condutivo possível, considerando o custo e as propriedades dos materiais, tais como resistência mecânica, condutividade térmica e resistência à corrosão, o material do duto a ser escolhido foi o cobre, o qual possui a condutividade térmica, conforme Incropera (2014 p. 624 e 625), de $k_{cu} = 400 \text{ W/m.K}$. Um duto de 240mm foi obtido, com diâmetro interno de 22mm e espessura de 1mm. Visando conseguir uma temperatura constante de 70°C na superfície do duto na região do aquecedor, foi feita uma resistência elétrica sob medida ($L=33\text{mm}$ e $\varnothing=19\text{mm}$) do tipo microtubular com potência de 80 Watts como mostra a Figura 36. Esta resistência foi acoplada ao duto no meio de sua geometria como visto na Figura 37.

Figura 36 – Resistência elétrica microtubular



Figura 37 – Resistência acoplada ao duto



Para captar as temperaturas de cada trecho, como se trata de temperatura de superfície de um metal, optou-se por utilizar os sensores termopares do tipo k. Estes elementos operam com temperaturas entre -200 e 1200 °C, que correspondem respectivamente a tensões de $-6,458$ mV a $48,838$ mV, tendo uma sensibilidade de aproximadamente $41\mu\text{V}/^\circ\text{C}$. Suportes de termoplástico ABS (*Acrylonitrile Butadiene Styrene*) foram confeccionados para garantir a total aderência destes termopares na superfície do duto.

Embora sejam resistentes a altas temperaturas, os suportes dos termopares adjacentes à resistência foram instalados com uma distância de segurança de 1mm para não sofrerem deformações devido à alta temperatura gerada na região pois os testes preliminares indicaram que a temperatura da resistência oscila entre aproximadamente 120 e 150°C para manter a região mediana do duto aquecida em 70°C , quando sob demanda. Levando em consideração que os suportes fabricados têm 10mm de largura e os termopares ficam instalados na metade exata de sua largura, vale mencionar que a distância que os termopares B e D ficam a partir das extremidades da resistência é de 6mm. As demais distâncias entre os outros termopares são de 10mm, exceto o termopar C que fica na região aquecida entre as espiras da resistência, a 21mm dos termopares B e D.


Desta forma, tal como descrito nas Figuras 38, 39 e 40, as distâncias entre os sensores são:

$$\text{LS1} = 21\text{mm}$$

$$\text{LS2} = 31\text{mm}$$

$$\text{LS3} = 41\text{mm}$$

Figura 38 – Medidor de vazão termal (MVT)



Fonte: Amaral et al., 2019 p. 2.

Figura 39 – Duto com resistência elétrica e termopares acoplados





Figura 40 – Protótipo instalado na bancada

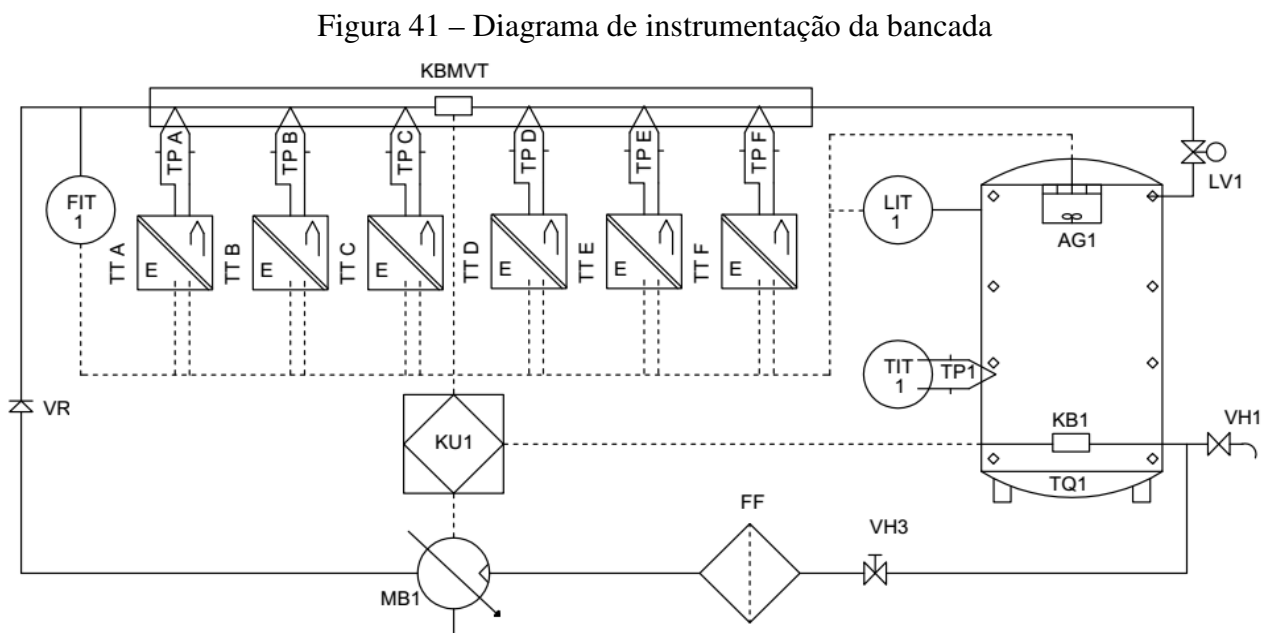


3.2 Construção da bancada

Para gerar os dados que posteriormente foram utilizados pelos algoritmos de aprendizado de máquinas para inferir a vazão, foi necessário gerar condições de reprodução de vazão de água em um ambiente controlado capaz de variar e armazenar os dados do processo. Por isto, para avaliar o desempenho do MVT, foi desenvolvida uma bancada projetada para ser capaz de mitigar possíveis erros oriundos de interferências internas ou externas seguindo princípios do padrão internacional 61508 da *International Electrotechnical Commission* (IEC 61508).

A bancada foi construída com equipamentos capazes de operar nos protocolos 4 a 20 mA/HART® e FOUNDATION™ FIELDBUS. Os transmissores utilizados são certificados para Níveis de Integridade de Segurança 2 (*Safety Integrity Level – SIL 2*) os quais são capazes de permitir uma medida de desempenho segura havendo um nível relativo de redução do risco entre 0,01 a 0,001. Os transdutores dos termopares estão ligados a uma placa condicionadora que converte os sinais de 4 a 20mA para 0 a 5V, o que possibilita a coleta de dados através da placa de aquisição de dados DAQ (*Data Aquisition*). O supervisorio utilizado para controlar a planta, ler e adquirir os dados de temperatura foi desenvolvido no software *Laboratory Virtual Instrumentation Engineering Workbench (LabVIEW)*.

A bancada está ilustrada na Figura 41, a qual indica seus principais componentes e é seguida da especificação de cada um.



- FIT1 - Computador de Vazão Eletromagnético INCONTROL série PRO1000
 - a) Faixa nominal 0,12 – 4,07 m³/h
 - b) Faixa calibrada 0,25 – 3,54 m³/h
 - c) Diâmetro ½”
 - d) Para 0,25 m³/h: erro de leitura -0,07% e incerteza 0,19%
 - e) Para 3,54 m³/h: erro de leitura 0,14% e incerteza 0,22%
- KBMVT
 - a) 6 termopares do tipo k (para ajuste das curvas foi considerado o maior erro de leitura como offset no LabView)
 - b) 1 uma resistência elétrica microtubular (L=33mm, Ø=19mm e P=80W)
- LIT 1 - Sensor de nível do tanque
- TIT 1 - Indicador de temperatura do tanque
- TT - Transdutores de sinais dos termopares
- LV1 - Válvula para ajuste fino da vazão
- AG1 - Conjunto agitador da água do tanque
- TP1 - Sensor de temperatura da água do tanque
- KB1 - Resistência de aquecimento
- TQ1 - Tanque com temperatura controlada
- KU1 - Painel de comando e controle, composto basicamente por fontes chaveadas, disjuntores, relés de comando e de estado sólido (PWM), borneiras, contadores e placas criadas para monitoração das variáveis
- VH1 - Válvula de esgotamento do tanque
- VH3 - Válvula para manutenção do tanque
- MB1 - Bomba d'água SEAFLO (24V, 4,5A, 0,68 m³/h)
- VR - Válvula retentora
- FF – Filtro de fluxo

A bancada retratada na Figura 42 consiste em um tanque (TQ1) com temperatura controlada, que serve como reservatório para possibilitar a recirculação da água. O controle de temperatura TQ1 é realizado através do software LabVIEW (KU1) que comanda a resistência elétrica (KB1), o agitador (AG1) e monitora o termopar TP1.

Um controlador PID, também implementado no Labview (KU1), garante a temperatura constante no elemento aquecedor (KBMVT). De acordo com a temperatura fornecida pelo

termopar C, localizado no centro do duto, KU1 varia a largura de pulso de um PWM que por sua vez, controla a tensão fornecida ao elemento aquecedor através de um relé de estado sólido. Da mesma forma, o controle de vazão da bomba é realizado por outro controlador PID que usa o medidor de fluxo eletromagnético não intrusivo (FIT1) como referência.

A saída do controlador PID está conectada ao outro PWM que controla a operação da bomba de água MB1. As válvulas VH1 e VH3 foram instaladas para facilitar a limpeza e manutenção do tanque. FV-01 é uma válvula de controle proporcional que pode ser usada para implementar um controle de vazão mais refinado, se necessário.

Figura 42 – Bancada com o protótipo em destaque



3.3 Aquisição e tratamento dos dados

O processo de operação da planta e aquisição dos dados ocorre através do supervisor, mostrado nas Figuras 43 e 44, que foi escrito em linguagem G e *Labview* que é responsável pelo controle dos atuadores, por receber e armazenar os dados do medidor de temperatura, executando de forma automatizada todas estas ações.

Figura 43 –Supervisor *Labview* – tela de comando



Além da tela principal, existem telas auxiliares para controle e monitoração detalhada de cada dispositivo da planta. O *Labview* também permite a construção de gráficos em tempo real das variáveis.

Figura 44 –Supervisório *Labview* – tela de aquisição

Para iniciar o experimento de coleta de dados, primeiramente, é ativada a resistência de aquecimento do protótipo. Através do controlador PID, a temperatura no meio do duto é mantida a um valor de 70 ° C. Após estabilizar a temperatura do elemento aquecedor, a bomba é ligada com a vazão mais alta a ser medida e aguarda-se a estabilização do perfil de temperatura. Todas as temperaturas do perfil são monitoradas para que os dados de temperatura e vazão sejam armazenados. Após a aquisição, a vazão é alterada para um novo valor para permitir a execução de uma nova medição. Estas medições são os dados a serem processados pela inteligência artificial que fará a inferência da vazão.

3.4 Métodos de aprendizado de máquinas para inferência da vazão

A partir das medições do perfil de temperatura no duto aquecido, modelos matemáticos podem ser usados para executar a inferência da vazão em um medidor. Há modelos estatísticos que buscam identificar relações entre duas ou mais variáveis chamados modelos de regressão. Hammerschmidt (2019), por exemplo, propôs um medidor de vazão por pulso térmico capaz de medir a velocidade do fluido e a difusividade térmica através de um modelo de regressão que utiliza as informações de termômetros espalhados ao longo de um duto com um elemento aquecedor. Estes modelos calculam a relação que existe entre as variáveis através da correlação entre elas, o que possibilita-o ser utilizado para inferir a vazão com os dados coletados.

Artigos recentes mostram um crescente uso de algoritmos de aprendizado de máquinas (AM) aplicados à criação de sensores inteligentes capazes resolver problemas de regressão,

bem como obter outras vantagens tal como a mitigação dos erros em suas medições. Nnabuife (2019) propôs um sensor ultrassônico capaz de identificar regimes de vazão de gases e líquidos usando efeito Doppler utilizando mapas virtuais de vazão e algoritmos de aprendizado de máquinas. Shaban (2014) propôs um sistema de medição de vazão de gás e líquido em dutos bifásicos com aplicação de técnicas de aprendizado de máquina que processam sinais de pressão diferencial.

Aprendizado de máquinas, conceitualmente, é uma sub-área da inteligência artificial que estuda algoritmos que podem aprender padrões a partir de dados e, com isso, aprimorar sua capacidade de fazer previsões. Estes algoritmos aprendem a partir de um treinamento realizado com amostras de um conjunto de dados (conjunto de treinamento) a fazer previsões e classificações de dados semelhantes aos utilizados em sua fase de treino. De modo geral, estes algoritmos podem ser separados em duas categorias de aprendizagem: supervisionado e não supervisionado. (KUHN et al, 2013).

No aprendizado supervisionado, cada observação dos dados forma dois vetores, sendo que um corresponde às entradas e o outro às respostas-alvo do modelo. O algoritmo ajusta os seus parâmetros com o objetivo de reduzir o erro entre as previsões obtidas pelo modelo e as respostas esperadas (resposta-alvo). Uma vez treinado, este modelo é capaz de fazer previsões em observações futuras com dados nunca antes vistos pelo modelo.

Já nos casos de aprendizado não supervisionado, para toda observação existe apenas um vetor que corresponde às entradas, não existindo respostas-alvo para guiar a tomada de decisão do modelo. Neste caso, o principal objetivo é aprender as relações entre variáveis no intuito de identificar como são agrupadas (JAMES et al., 2014).

De um modo geral, no aprendizado supervisionado deseja-se encontrar uma função que mapeia o vetor de atributos \mathbf{x} no vetor de saída \mathbf{y} . Quando a saída é discreta, diz-se que este é um problema de classificação, pois cada valor discreto de \mathbf{y} representa uma classe. No caso onde a saída é contínua temos um problema de regressão, como é o caso do MVT onde as temperaturas são o vetor de entrada e a vazão o vetor de saída.

Desta forma, a inferência da vazão é vista como um problema de regressão, onde a avaliação do desempenho de um algoritmo de aprendizado de máquina em um determinado conjunto é realizada através da medição da diferença entre o valor esperado e o valor obtido. No contexto deste trabalho, o erro médio quadrático (EMQ) foi a medida utilizada e é dado por:

$$EMQ = \frac{1}{n} \sum_{i=1}^n (y_i - y_n)^2 \quad (16)$$

Sendo:

y_n = respostas do modelo

n = número de respostas

A seguir têm-se sucintas descrições dos algoritmos de aprendizado de máquinas aplicáveis em problemas de regressão. Descrições mais aprofundadas podem ser encontradas nas referências bibliográficas.

3.4.1 – Regressão linear múltipla

O método da regressão linear (MRL) é um método estatístico resistente a ruídos nos dados de entrada para estimar o desempenho de uma variável em relação à outra através de equações matemáticas (Aguirre, 2007). Uma reta de regressão, também chamada de reta dos mínimos quadrados, é traçada sendo capaz de descrever a relação existente entre duas variáveis. O MRL é usado para prever respostas contínuas e resulta em uma descrição interpretável de relações entre variáveis predictoras e a resposta de interesse (Santos, 2018).

O MRL múltiplo é uma generalização do modelo simples de regressão linear, o qual passa a considerar mais variáveis independentes. O modelo cria uma reta estimativa (\hat{y}_i) que estipula valores iniciais aos coeficientes α e β que podem ser calculados tanto analiticamente, através do método da pseudo-inversa, quanto de forma iterativa pela descida do gradiente.

$$y = \alpha_1 x_1 + \alpha_2 x_2 + \dots + \alpha_m x_m + \beta + \varepsilon \quad (16)$$

Considerando as temperaturas como um vetor de entrada e a vazão como um vetor de saída, a diferença entre o valor do conjunto de dados e o valor estimado é o erro (ε_i) de cada ponto. O método dos mínimos quadrados (MMQ) é utilizado para minimizar o quadrado dos resíduos da regressão, fazendo a soma quadrática dos erros (E).

$$\varepsilon_i = y_i - \hat{y}_i = y_i - \alpha x_i - b \quad (17)$$

$$E = \sum_{i=1}^n \varepsilon_i^2 \quad (18)$$

3.4.2 – Algoritmo kNN Regressor

O algoritmo kNN (*k-nearest neighbors*) é tipificado como não-paramétrico tendo em vista que não faz suposição sobre o modelo para ser ajustado nem pressupõe qual a distribuição dos dados de entrada (ALTMAN, 1991). É um algoritmo categorizado como *Lazy Learner*, uma vez que no treinamento, apenas armazena as entradas de treinamento \mathbf{x} junto às respectivas saídas desejadas. Para cada dado de entrada novo \mathbf{x}' , uma saída gerada pelo kNN depende das saídas associadas aos padrões de treinamento que estão mais próximas à entrada \mathbf{x}' no espaço de atributos.

Em regressão, a saída do kNN Regressor (kNNR) para um novo dado de entrada \mathbf{x}' pode ser escrita de uma forma geral como visto na Equação 19:

$$\hat{y}(\mathbf{x}') = \frac{\sum_{j=1}^k w_j y_j (x \in N_k(\mathbf{x}'))}{\sum w_j} \quad (19)$$

Onde:

$N_k(\mathbf{x}')$ denota a vizinhança de \mathbf{x}' formada pelos padrões de treinamento $x(i)$ que correspondem aos k vizinhos mais próximos a \mathbf{x}' ;

w_j representa o peso associado ao j -ésimo vizinho de \mathbf{x}' .

Desta forma, o uso do kNN Regressor envolve a definição de uma métrica de distância a ser calculada no espaço de atributos a fim de determinar os vizinhos mais próximos e um valor para o parâmetro k que determina a quantidade de vizinhos mais próximos que são levados em consideração na geração da saída. O valor da saída será dado por uma média ponderada dos valores de saídas dos vizinhos.

No caso do MVT, é fornecido para o kNNR o vetor de entrada composto pelos valores de temperatura. Com este vetor, ele busca no conjunto de treinamento um número k de vizinhos mais próximos a este vetor e a vazão resultante será dada pela média das vazões dos k vizinhos mais próximos encontrados. O k é o hiperparâmetro ajustado.

3.4.3 – Árvore de Decisão

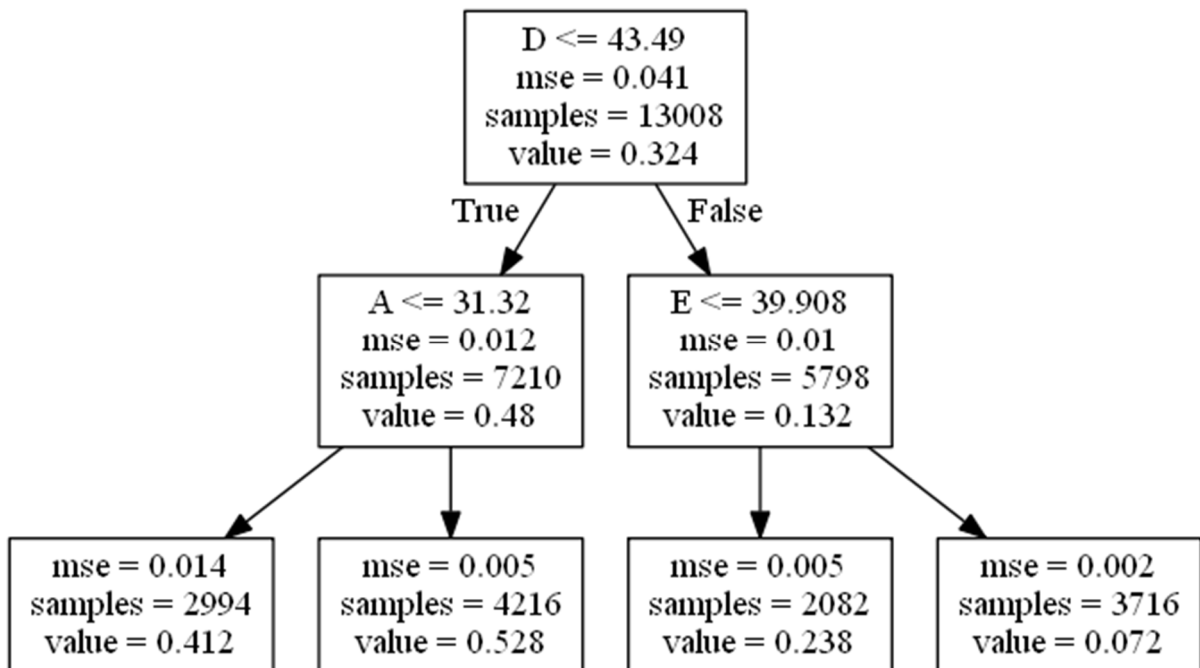
A árvore de decisão (BREIMAN, 1984) consiste em um arranjo hierárquico formado de nós e ramos (WITTEN et al. 2016) o qual pode ser usado tanto para regressão quanto para

classificação. Existem três tipos de nós: a raiz que contém apenas ramos de saída, os nós internos que possuem um ramo como entrada e dois ramos de saída e os nós terminais que não possuem ramos de saída. Cada nó não terminal representa um teste em uma das variáveis de entrada (atributo) e cada ramo de saída representa um dos possíveis resultados do teste.

Quando se deseja saber a classe de um certo vetor de entrada, começa-se pela raiz testando a variável presente neste nó, e então, passa-se a percorrer a árvore, percorrendo o ramo correspondente ao resultado do teste do atributo. Este processo se repete até chegar a um nó terminal (folha) onde a classe é determinada pela classe majoritária dos elementos do conjunto de treinamento que seriam colocados nesta folha, se seguissem a sequência de testes presentes na árvore.

No caso de uma regressão, a previsão da saída é dada pela média dos elementos do conjunto de treinamento que foram agrupados naquela folha, tal como descrito de modo simplificado na Figura 45.

Figura 45 - Esquema de um modelo de Árvore de Decisão simplificado em dois níveis



No caso do MVT, é fornecido um vetor de temperaturas para o modelo árvore de decisão, o qual é submetido a n nós da árvore. A cada nó, o conjunto de dados é subdividido em grupos menores cujas características sejam mais parecidas. O valor de n define a profundidade da árvore, que no caso da figura 45, possui valor 2. Os nós terminais, localizados na base da árvore, indicam o valor da média das vazões bem como o número de amostras e o

erro médio quadrático. Os hiperparâmetros ajustados são o número mínimo de amostras por folhas e a profundidade da árvore (níveis).

3.4.4 – Florestas Aleatórias

Florestas Aleatórias são modelos que têm como base o algoritmo de árvores de decisão, mas que são capacitados para lidar com conjuntos de alta dimensão. Assim como no caso das árvores de decisão, estes modelos são muito utilizados tanto para classificação quanto para regressão. Florestas Aleatórias combinam os resultados de um conjunto de árvores de decisão afim de obter uma resposta como saída, a qual tenderá a representar um desempenho superior que o obtido individualmente em cada árvore devido à consequente redução de variância.

O número de árvores (estimadores) é um hiperparâmetro da floresta aleatória. Ele deve ser ajustado para garantir que o modelo seja robusto e que ao mesmo tempo seja acurado.

3.4.5 – *Gradient Boosting Regressor*

Também conhecido como *Gradient Boosted Regression Tree* (GBRT), este é um poderoso modelo para resolver problemas preditivos (CHEN et al., 2016). Age como um problema de otimização matemática onde o objetivo é minimizar uma função de custo adicionando “modelos mais fracos” usando o procedimento do Gradiente Descendente.

É composto por três elementos principais: uma função de custo a ser otimizado; um modelo fraco para fazer previsões; um modelo aditivo para adicionar um modelo fraco para minimizar a função de custo. A função de custo depende do problema que se quer resolver. Por exemplo, para regressão, o erro médio quadrático é habitualmente usado. Árvores de decisão são usadas como modelos fracos e a estratégia empregada acrescenta uma árvore de cada vez e as árvores anteriores não são modificadas. Um procedimento de descida de gradiente é utilizado para minimizar o custo cada vez que uma árvore é anexada.

No caso do MVT, de forma análoga ao tópico anterior, um vetor de temperaturas é fornecido ao modelo o qual é submetido à sucessivas árvores de decisão. Seu diferencial é que cada árvore adicionada busca diminuir o erro obtido com a utilização das árvores adicionadas anteriormente. O hiperparâmetro ajustado neste caso é o número de árvores sucessivas.

3.5 Rede Neural Artificial

Assim como em aprendizado de máquinas, artigos recentes também mostram um crescente uso de algoritmos de Redes Neurais Artificiais (RNA) aplicados em sensores de vazão para resolver problemas de regressão.


Em Dave (2020), foi proposto um sistema de inferência de vazão de gás e líquidos utilizando um modelo de rede neural treinado por um sensor do tipo *wire-mesh*. Em Giannetti (2019), é feito um estudo de previsão da distribuição de fluxo bifásico nos microcanais de trocadores de calor usando rede neural artificial. Em Esfe (2015), propõe-se o uso de um modelo de rede neural artificial aplicada à previsão e modelagem de condutividade térmica de nanofluidos de água Al_2O_3 usando regressão não linear. Esta pesquisa permitiu evidenciar que é possível utilizar ferramentas de redes neurais para problemas de regressão, detectar e corrigir comportamentos indesejados no protótipo.

A seguir têm-se uma sucinta descrição do funcionamento de uma RNA e alguns exemplos de algoritmos. Descrições mais aprofundadas podem ser encontradas nas referências bibliográficas.

3.5.1 – Redes neurais artificiais do tipo *feed-forward*

Em aprendizado de máquinas, as RNA exemplificadas nas Figuras 46 e 47 são modelos que se inspiram na estrutura de um sistema neural biológico e aprendem padrões através de observações. A RNA perceptron é uma rede neural treinável com uma arquitetura de camada única, composta por uma camada de entrada e outra de saída. Uma rede perceptron comum ou modificada com várias unidades de saída é um modelo linear e isto proíbe sua aplicação em tarefas que envolvam padrões de dados complexos, mesmo com o uso de funções de ativação não lineares na camada de saída.


Figura 46 – RNA de camada única



Fonte: Shen et al, 2017 p.224

Essa limitação pode ser superada com a introdução das chamadas camadas escondidas entre a camada de entrada e a camada de saída.

Figura 47 – RNA multicamadas



Fonte: Shen et al, 2017 p.224

Em uma RNA multicamadas, as unidades das camadas vizinhas são totalmente conectadas uma às outras, mas não há conexões entre unidades na mesma camada. Para uma RNA de duas camadas, também conhecida como perceptron multicamadas, dado um vetor de entrada $\mathbf{v} = [v_i] \in \mathbb{R}^D$, podemos escrever a função de estimativa de uma unidade de saída y_k como uma equação da seguinte maneira:

$$y_k(\mathbf{v}; \Theta) = f^{(2)} \left(\sum_{j=1}^M W_{kj}^{(2)} f^{(1)} \left(\sum_{i=1}^D W_{ji}^{(1)} v_i + b_j^{(1)} \right) + b_k^{(2)} \right) \quad (20)$$

Sendo:

- $f^{(1)}$ e $f^{(2)}$ as funções de ativação de cada camada;
- M o número de camadas escondidas;
- Θ o conjunto de parâmetros W (peso) e b (bias);

Conforme Shen (2017), o uso prático de redes neurais requer que o conjunto Θ dos parâmetros do modelo sejam aprendidos através do conjunto de dados. O problema da aprendizagem de parâmetros pode ser formulado como a minimização da função de custo. Do ponto de vista da otimização, a função de custo E para redes neurais é altamente não linear e não convexa. Portanto, não há solução analítica do conjunto de parâmetros Θ . Em vez disso,

pode-se usar um algoritmo de descida de gradiente atualizando os parâmetros iterativamente. Para utilizar um algoritmo de descida de gradiente, deve haver uma maneira de calcular um gradiente $\nabla E(\Theta)$ avaliado no conjunto de parâmetros Θ .

Para uma rede neural *feed-forward*, o gradiente pode ser avaliado com eficiência por meio da retropropagação do erro. Uma vez conhecido o vetor gradiente de todas as camadas, os parâmetros Θ podem ser atualizados da seguinte maneira:

$$\Theta^{(\tau+1)} = \Theta^{(\tau)} - \eta \nabla E(\Theta^{(\tau)}) \quad (21)$$

Sendo:

- η a taxa de aprendizado;
- τ o índice da interação.

No caso do MVT, após toda a fase de treinamento da rede, um vetor de entrada com os valores de temperatura é dado ao modelo e ele, com base na conhecimento obtido através do treinamento é capaz de inferir a vazão com precisão. Os hiperparâmetros ajustados são a quantidade de neurônios, épocas de treinamento (número de amostras), e número *batch* (quantidade de dados por amostra).

3.5.2 – Aprendizagem Profunda

Os modelos de aprendizagem profunda são redes neurais com um número maior (≥ 3) de camadas ocultas. A Aprendizagem Profunda (*Deep Learning* - DL) em Bengio (2009) é descrita como um modelo particular de aprendizado de máquina dotado de muita flexibilidade e alta performance por fazer a representação dos dados como uma hierarquia aglomerada de funções matemáticas, cada qual associada a uma camada oculta distinta.

Os modelos DL são aplicáveis em problemas que visem descobrir atributos de forma automatizada e de maneira hierárquica através da composição de módulos simples mas não lineares. São modelos que possibilitam que funções de muita complexidade possam ser aprendidas (LECUN et al., 2015). Outro aspecto importante de um modelo DL é poder capacitar uma máquina a aprender um programa com mais de uma etapa. Cada camada é considerada um estado da memória após o término de outro conjunto de instruções em paralelo. Modelos com maior grau de profundidade podem executar um número maior de instruções em sequência, o que confere aos modelos DL grande poder de processamento, tendo em vista que as

instruções posteriores podem fazer referências aos resultados das etapas passadas. (GOODFELLOW et al., 2016).


Estes modelos ainda têm a capacidade de, em cada camada interna, conter uma função de custo e de ativação diferente das outras camadas. Desta forma, a aplicação de múltiplas camadas em modelos computacionais possibilita uma melhora drástica na solução de problemas tanto de classificação quanto regressão. No caso do MVT, o processo é análogo ao da RNA mas com o incremento de mais um hiperparâmetro que é o número de camadas escondidas.

3.5.3 – Dropout


O *Dropout* é uma técnica desenvolvida para lidar com problemas de *overfitting* que ocorrem em grandes redes. Normalmente, uma forma de reduzir o *overfitting* é através da agregação de modelos. Entretanto, no caso de grandes RNA, a ideia de calcular a média dos resultados de muitas redes treinadas separadamente é custosa. É difícil treinar muitas arquiteturas diferentes porque o ideal é obter hiperparâmetros para cada arquitetura de forma dedicada, mas isto requer um alto custo computacional. Grandes redes normalmente exigem grandes quantidades de dados de treinamento, que nem sempre estão disponíveis.

A técnica *Dropout* foi então criada para prover uma forma de combinar muitas redes neurais com diferentes arquiteturas de maneira eficiente e assim evitar o *overfitting*. O termo “*dropout*” refere-se a abandono de unidades, tanto ocultas quanto visíveis, em uma rede neural. Ao retirar uma unidade, o objetivo é removê-la temporariamente da rede, juntamente com todas as suas conexões de entrada e saída, sendo a escolha de quais unidades abandonar é realizada de forma aleatória. A aplicação do *Dropout* em uma rede neural equivale a reduzir a rede. A rede reduzida consistirá em todas as unidades que sobreviveram ao abandono, conforme mostra a Figura 48.

Figura 48 – Exemplo de *Dropout*



(a) Rede Neural Padrão



(b) RNA após aplicação do *Dropout*

Fonte: Srivastava et al, 2014 p. 1930.


No caso do MVT, o processo é análogo ao do DL mas com o incremento de mais um hiperparâmetro que é a taxa de *dropout* (*dropout rate*).

Tendo em vista todas estas ferramentas computacionais, o próximo capítulo abordará os resultados obtidos com cada uma delas.

4 RESULTADOS EXPERIMENTAIS


Os modelos de aprendizado de máquinas foram desenvolvidos em linguagem *Python* utilizando as bibliotecas *Scikit-Learn* 0.20.3, *Tensorflow* 1.13.1 e *Keras* 2.2.4 de forma que recebessem um vetor com cinco componentes de entrada e apresentassem uma saída, tal como representado na Figura 49.

Figura 49 – Representação típica do modelo de regressão multivariado



Desta forma, sabendo-se que as entradas são as temperaturas dos termopares, a saída a vazão inferida e os modelos são uma RNA ou AM, têm-se os seguintes modelos típicos de regressão multivariada representados na Figura 50:

Figura 50 – Representação dos modelos de RNA e AM



Nesta parte do estudo, os dados coletados em bancada são processados pelos modelos de AM e RNA, sendo ordenados pelo melhor desempenho. Os dados de temperatura são as entradas (x) dos modelos enquanto os dados de vazão serão as saídas (y). A partir dos dados reunidos, é possível comparar o perfil previsto pela modelagem no capítulo 2 e o perfil obtido pelo experimento. De modo análogo ao capítulo 2, a Figura 51 mostra o perfil obtido no

experimento enquanto a Figura 52 mostra um corte transversal indicando os intervalos específicos de vazão.

Figura 51 - Perfil das temperaturas no duto em função da vazão na bancada






Figura 52 – Perfil de temperatura obtido no experimento por intervalos de vazão




Com base nos dados de temperatura obtidos no experimento, é possível unir e comparar as informações dos perfis da modelagem feita no COMSOL e do obtido através de simulações na bancada. A Figura 53 mostra as linhas de vazão mínimas e máximas do COMSOL e do MVT, possibilitando a comparação com a Figura 24 do capítulo 2, a qual mostra as curvas típicas de um calorímetro.

Figura 53 – Comparativo Modelagem x Experimento



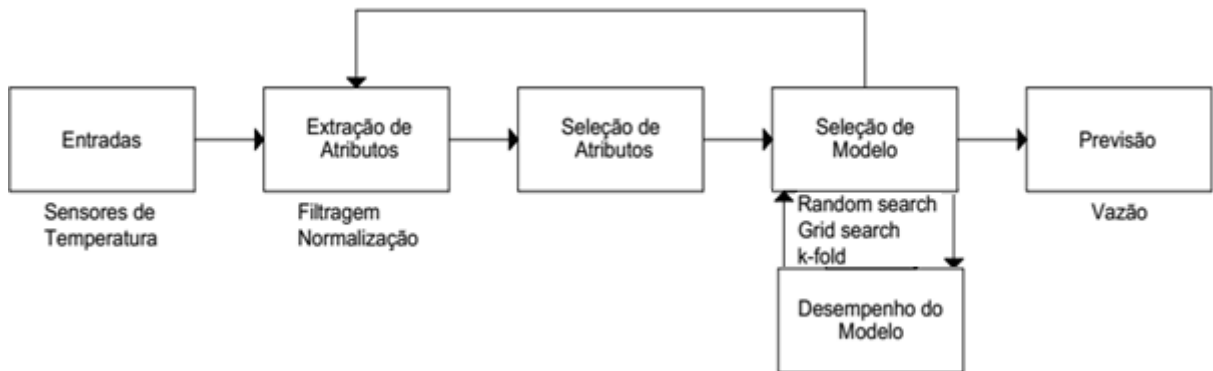
Calculando-se a diferença percentual entre as temperaturas do perfil do modelo criado no COMSOL e do perfil obtido com o MVT na bancada, encontra-se uma diferença na média dos erros absolutos de cada sensor de 7% na vazão mínima e 5% na vazão máxima conforme o gráfico mostrado na Figura 54.

Figura 54 – Média dos erros absolutos entre as temperaturas de todos os termopares previstas no modelo e medidas no experimento por faixa de vazão



A partir desta comprovação de que a modelagem condiz com os resultados obtidos pela bancada, deu-se início ao projeto do sistema de aprendizado de máquinas que conceitualmente pode ser representado pelo fluxograma proposto pela Figura 55.


Figura 55 – Projeto conceitual de sistema de aprendizado de máquinas aplicado ao MVT



As entradas são os dados de temperatura ainda em forma bruta, conforme mostra a Figura 56. Na fase de extração de atributos ocorre a filtragem e a normalização destes dados. Na fase de seleção de atributos é feita a escolha dos dados, sendo nesta etapa decidido que a temperatura do sensor C seria descartada tendo em vista que seu valor é sempre 70°C. A fase de seleção do modelo obtém os hiperparâmetros do modelo enquanto que a fase de desempenho avalia o resultado medindo o erro médio quadrático. A previsão mostra o resultado final.

Através dos valores coletados de vazão e de temperatura de cada sensor, é possível agora construir um gráfico que permite comparar visualmente as variações. Fica evidente que há uma maior influência da temperatura e da vazão nos termopares B, E e F. Também se pode testemunhar o efeito do aquecimento da água devido à recirculação do líquido através do sensor A. O procedimento experimental gerou três arquivos de dados com 18.584 medições cada, totalizando um *dataset* de 55.752 pontos de medição para serem processados e utilizados para inferir a vazão pelo protótipo.

Figura 56 – Dados adquiridos sem tratamento

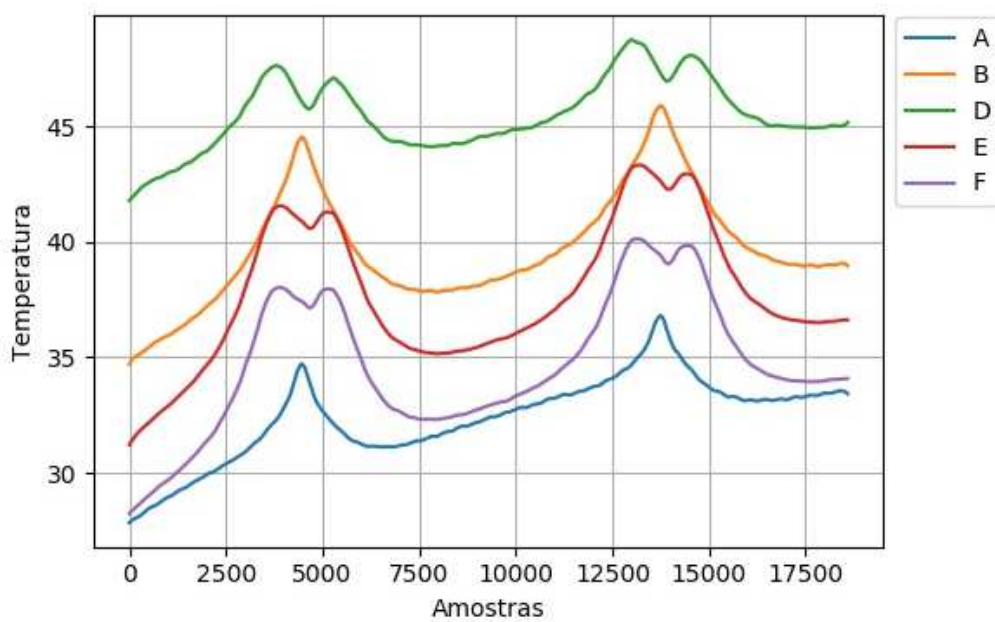


Os sinais adquiridos foram filtrados para retirar os ruídos presentes nas formas de onda conforme mostra a Figura 57, os quais são comuns em equipamentos secundários de medição que captam sinais elétricos em um sistema físico.

O filtro utilizado foi o Savitzky – Golay, um filtro digital de média móvel que retirou parte das flutuações nas medidas sem provocar distorção ou alteração da tendência do sinal. Seu método é conhecido como “convolução” pois consiste em ajustar sucessivos subconjuntos de dados adjacentes com um polinômio de baixo grau através do método dos mínimos quadrados lineares.

O método foi popularizado em Savitsky et al (1964) e é comumente usado em dados de séries temporais para atenuar flutuações.


Figura 57 – Dados adquiridos após a filtragem



Na fase posterior à filtragem, os três arquivos são destinados a funções distintas, sendo o arquivo data1 utilizado para treinamento, data2 para validação e data3 para teste, conforme visto na Figura 58. Desta maneira são usados tanto pelos algoritmos de RNA quanto pelos de AM para obtenção do melhor modelo de inferência de vazão.

Após a filtragem os dados são normalizados tendo seus valores mínimos e máximos igualados respectivamente a 0 e 1, visto que esta estratégia demonstrou um melhor desempenho tanto nos modelos de RNA quanto nos de AM.

Figura 58 – Perfil típico das vazões e temperaturas dos sensores



A seguir, têm-se os resultados obtidos pelos modelos. A métrica utilizada para avaliação dos resultados, tanto com aprendizado de máquinas quanto com redes neurais, foi o erro de fundo de escala. Estes foram calculados comparando a resposta do modelo com a vazão do medidor de referência.

4.1 Resultados obtidos

Os melhores modelos de redes neurais e aprendizado de máquinas tiveram seus hiperparâmetros (número de camadas e de neurônios, épocas, *batch size*, função de ativação e otimizador no caso de RNA e demais parâmetros de AM) selecionados utilizando dois métodos de busca distintos: *random search* e *grid search*. O primeiro testa combinações aleatórias dos hiperparâmetros em um determinado espaço de busca enquanto que o segundo testa todas as combinações possíveis.

Estas buscas de hiperparâmetros são feitas utilizando a validação cruzada, onde utiliza-se apenas um conjunto de dados (conjunto de treinamento), formado pela junção dos conjuntos de treino e validação no caso deste experimento, e o mesmo é dividido em k pastas (*k-fold*). O conjunto é treinado em $k-1$ pastas e testado na pasta que não foi utilizada.

Uma vez encontrados os melhores hiperparâmetros, o modelo é retreinado com o mesmo conjunto de dados e após a fase de treino é aplicada a fase de teste, na qual é possível medir a capacidade de generalização. O critério de escolha do melhor modelo nesta fase foi o menor

erro médio quadrático (EMQ) obtido utilizando o mesmo conjunto de treinamento na fase de teste do modelo.

A Tabela 4 mostra os resultados do EMQ de cada modelo, bem como os respectivos hiperparâmetros.

Tabela 4 - Melhores modelos obtidos de cada algoritmo proposto ($k=10$)

Modelo	Busca	Hiperparâmetros	EMQ (Treino)
Árvore de decisão	gridsearch	profundidade=20, amostras por folha=1	5,25E-07
Floresta Aleatória	gridsearch	num de estimadores=400	1,62E-06
KNNR	gridsearch	número de vizinhos=3	6,06E-06
Gradient Boosting	gridsearch	num de estimadores=400	1,48E-05
Deep	gridsearch	* n3: 100, n2: 100, n1: 100, épocas: 1000, batch: 128	4,90E-05
Dropout input	gridsearch	n3: 100, n2: 100, n1: 100 épocas: 100, dropout_rate: 0.0, batch: 64	1,04E-04
MLP	Random	otimizador: Adam, n: 100, épocas: 500, batch: 64, função de ativ: relu	1,18E-04
SGD	gridsearch	batch: 64, épocas: 1000, taxa de aprendiz: 0.1, momentum: 0.8, n: 100	1,29E-04
Dropout	Random	n3: 10, n2: 10, n1: 10, épocas: 100, dropout_rate: 0.0, batch: 64	3,36E-03
Regressão Linear	-	-	3,46E-03

*n1, n2 e n3 = número de neurônios em cada camada.

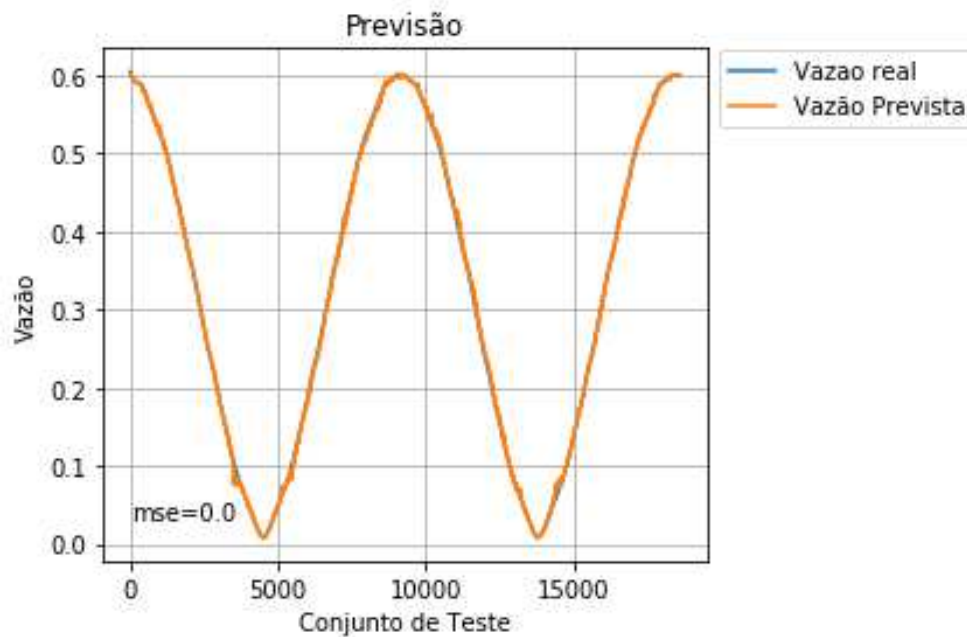
Os modelos de RNA foram então submetidos às fases de treinamento, validação e teste utilizando o conjunto de dados conforme a Figura 58. Vale ressaltar que na fase de validação de uma RNA é utilizado o critério da parada antecipada para, durante a escolha dos hiperparâmetros, prevenir a ocorrência do *overfitting*. Este procedimento previne que um modelo não se ajuste tanto às idiossincrasias do conjunto de treinamento de modo que se mostre ineficaz para fazer previsões em novos conjuntos de dados, perdendo assim sua capacidade de generalização.

Já os modelos de AM foram submetidos às fases de treinamento e teste, sendo o conjunto de treino um conjunto de dados correspondente à soma dos conjuntos data1 e data2 mostrados na Figura 58. Os modelos foram classificados de acordo com o menor FSD (*full scale deflection* - erro de fundo de escala) tal como mostra a Tabela 5.

Tabela 5 - Melhores modelos segundo o critério do erro de fundo de escala

Modelo	EMQ (Teste)	FSD
Gradient Boosting	1,18E-05	0,0354
Deep	4,90E-05	0,0367
MLP	1,20E-04	0,0412
Floresta Aleatória	1,11E-05	0,0444
SGD	1,32E-04	0,0485
KNNR	1,08E-05	0,0489
Dropout input	1,05E-04	0,0508
Árvore de decisão	1,76E-05	0,0674
Regressão Linear	3,46E-03	0,2004
Dropout	3,35E-03	0,2032

Com a metodologia proposta, o modelo de AM *Gradient Boosting* teve o melhor desempenho segundo o critério do menor erro fundo de escala, tal como mostra a Figura 59.

Figura 59 – Vazão real e vazão prevista pelo modelo de AM *Gradient Boosting*

Uma métrica auxiliar utilizada para atestar a estabilidade da medição do MVT é o erro fiducial, a qual mede percentualmente o tamanho do erro em relação a uma determinada faixa de vazão.

$$\text{erro fiducial} = \frac{\text{vazão}_{\text{modelo}} - \text{vazão}_{\text{referência}}}{\text{vazão}_{\text{referência}}} \quad (22)$$

Esta medida possibilitou atestar a estabilidade de leitura do MVT, quando operando com o algoritmo *Gradient Boosting Regressor*, entre as faixas de vazões 0,11 e 0,6m³/h estando o erro fiducial entre -0,45 e 0,5% conforme as Figuras 60 e 61.

É possível observar que nas vazões mais baixas o erro fiducial é muito maior. Isto deve-se ao fato do medidor de referência da bancada ter como limite mínimo da sua vazão nominal o valor de 0,12m³/h. Por isto, o modelo apresenta uma melhora significativa a partir deste valor de vazão.

Figura 60 – Erro fiducial de 0.06 a 0.33m³/h






Figura 61 – Erro fiducial de 0.34 a 0.6m³/h



4.1.1 – Mudança na extração de atributos

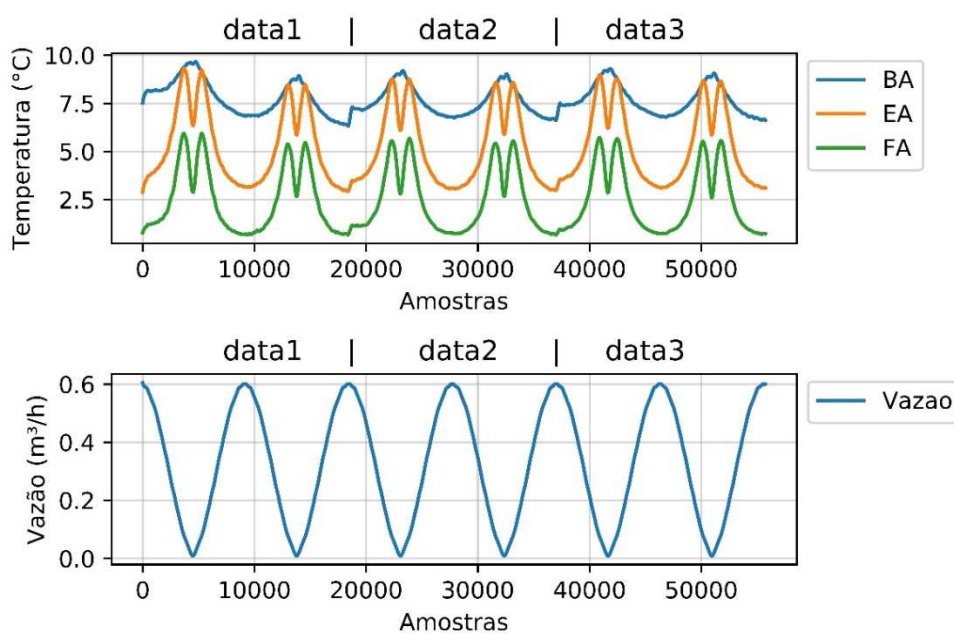
Visando melhorar o desempenho dos modelos, observou-se que um rearranjo das entradas diminuía significativamente os erros médio quadrático e de fundo de escala. Por isto foi implementada uma mudança nos códigos de processamento. Sucessivos testes comparativos demonstraram que, em todos os casos, erros médio quadráticos e de fundo de escala reduziam significativamente quando, em vez de utilizar os dados tais como mostrados na Figura 62, se utilizasse o valor da diferencial de temperatura (ΔTemp) entre os sensores B e A (BA), E e A (EA) e F e A (FA). A configuração dos modelos passou então a ter a seguinte forma:

Figura 62 – Representação dos modelos de RNA e AM usando o ΔTemp



Desta forma, os arquivos utilizados passaram a ter a forma apresentada na Figura 63.

Figura 63 – Vazões e diferenciais de temperatura (ΔTemp)



Diferente da forma anterior onde cada conjunto era usado especificamente para uma das fases (treinamento, validação ou teste), desta vez foi aplicada a validação cruzada em todo o conjunto de dados. Isto deu uma nova forma aos conjuntos, cujos tamanhos para as fases de treino, validação e teste passaram a corresponder a respectivamente 50, 30 e 20% do total do conjunto. Para facilitar a compreensão visualmente, o conjunto de teste foi reordenado após a validação cruzada tal como demonstrado na Figura 64.

Figura 64 – Conjunto de teste ordenado




Tabela 6 - Melhores modelos obtidos pelos algoritmos propostos (Δ Temp)

Modelo	Hiperparâmetros	EMQ (treino)
KNN	número de vizinhos=3	5,13E-09
Floresta Aleatória	num de estimadores=400	7,69E-07
Árvore de Decisão	profundidade=17, amostras por folha=1	1,95E-06
Gradient Boosting	num de estimadores=400	4,98E-05
Deep	n3: 100, n2: 100, n1: 100, épocas: 1000, batch: 128	8,60E-05
Dropout	n3: 10, n2: 10, n1: 10, épocas: 100, rate: 0.0, batch: 64	1,02E-04
MLP	otimizador: Adam, n: 100, épocas: 500, batch: 64, função de ativ: tanh	2,29E-04
SGD	batch: 64, épocas: 1000, rate: 0.1, momentum: 0.8, n: 100	2,92E-04
Dropout input	n1 = 10, n2 = 10, n3 = 100, épocas = 100, rate = 0.0, função de ativ = tanh	3,20E-04
Reg. Linear	-	7,17E-04

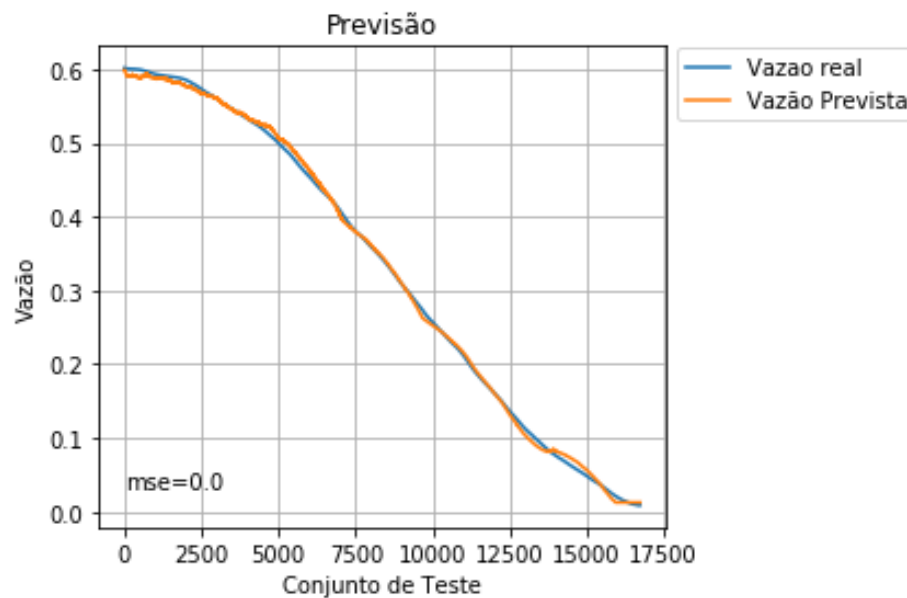
Da forma análoga à metodologia anterior, os modelos foram então submetidos às mesmas fases de treinamento, validação e teste com o mesmo conjuntos de dados propostos na Figura 63, porém após o processo de validação cruzada, sendo classificados de acordo com o menor erro de fundo de escala como mostra a Tabela 7.

Tabela 7 - Melhores modelos segundo o critério do erro de fundo de escala (ΔTemp)

Modelo	EMQ (teste)	FSD
Dropout	5,85E-04	0,018
MLP	5,14E-04	0,031
Dropout input	3,43E-04	0,037
SGD	3,54E-04	0,037
Gradiente Boosting	1,59E-04	0,046
Deep	6,02E-04	0,055
Floresta Aleatória	2,27E-04	0,058
KNN	3,19E-04	0,069
Árvore de Decisão	2,78E-04	0,070
Reg. Linear	2,27E-03	0,070

Com a metodologia de inferência da vazão por ΔTemp , o modelo de RNA *Dropout* teve o melhor desempenho segundo o critério do menor erro de fundo de escala como mostra a Figura 65.

Figura 65 – Vazão real e vazão prevista pelo modelo de RNA *Dropout*



Também foi feita a mesma análise do erro fiducial por faixa, como mostra as Figuras 66 e 67:

Figura 66 – Erro fiducial de 0.06 a 0.33m³/h (Δ Temp)





Figura 67 – Erro fiducial de 0.34 a 0.6m³/h (Δ Temp)



Esta medida possibilitou atestar que a variação do erro por faixa do MVT, ao utilizar RNA, entre as faixas de vazões 0.14 e 0.6m³/h está entre -2,6 e 2,3% conforme as figuras 66 e 67.

CONCLUSÕES

As tecnologias não-intrusivas de medição de vazão são alvos de constantes melhorias para a obtenção de medições cada vez mais precisas e estáveis. Embora sejam promissoras, as técnicas atuais ainda têm deficiências que precisam ser tratadas.

Neste projeto, foi construído o protótipo de um medidor de vazão termal não intrusivo de líquidos de pequeno diâmetro que mostrou a eficiência do uso de algoritmos de aprendizado de máquinas para a diminuição do erro de fundo de escala em baixas vazões. Em conjunto com o MVT também foi construída uma bancada de testes, a qual possibilitou simular vazões de líquidos com bastante versatilidade e criar cenários distintos para analisar o comportamento do protótipo.

Tendo em vista que o objetivo no MVT é medir a temperatura em pontos específicos do duto de modo que possibilite a reprodução do perfil de temperaturas da superfície, para a modelagem do medidor e considerando como fluido a água, foi utilizado o programa de modelagem COMSOL Multiphysics para decidir em quais pontos do duto seriam instalados os sensores e o aquecedor.

Para fazer a simulação numérica, foi idealizada uma geometria retangular semelhante ao calorímetro cilíndrico. O ponto de aquecimento foi escolhido de maneira que se encontrasse no meio da geometria. Para a construção, considerou-se o cobre como material do duto ($L=240\text{mm}$, $\varnothing=22\text{mm}$, espessura= 1mm). O modelo matemático obtido se propôs a descrever um calorímetro num duto de cobre cujo elemento aquecedor se mantenha a uma temperatura constante de 70°C e cuja vazão varie de $0,05$ a $0,6\text{m}^3/\text{h}$ com dois sensores de temperatura a montante e três a jusante. A determinação dos pontos de medição das temperaturas do perfil foi feita tendo como critério a distância que possibilitasse a obtenção da maior quantidade de informação possível para possibilitar a maior exatidão possível na inferência da vazão.

De forma experimental, foi possível reconstruir o perfil de temperaturas e observar a sua dinâmica em função das variações de vazão durante os testes em bancada. Concluiu-se que quando o instrumento era submetido a baixas vazões, o perfil não reproduzia os resultados satisfatórios, principalmente quando operava em regiões abaixo do limite de vazão mínimo do medidor de referência ($0,12\text{ m}^3/\text{h}$). No entanto, a pesquisa bibliográfica desenvolvida mostrou o crescente uso de aprendizado de máquinas em sistemas de medição de vazão que ajudavam a melhorar estes resultados. Foram desenvolvidos dois métodos neste trabalho, um que considerava todo o perfil de temperatura e outro que possibilitava rearranjar as entradas de temperaturas no modelo que modo que a diferença entre elas fosse o vetor de entrada.

A inferência da vazão a partir do uso de métodos de aprendizado de máquinas como os algoritmos K-NN, Árvore de Decisão, Florestas Aleatórias e GBR mostrou uma maior capacidade de manter a leitura estável ao longo das mudanças de vazão, segundo o critério do erro fiducial, porém tendo um baixo desempenho sob a métrica do erro de fundo de escala nas vazões mais baixas. O algoritmo GBR teve uma estabilidade dos valores de vazão entre -0,45 e 0,5% das faixas e um erro de fundo de escala de 3,5%.

Já as redes neurais tiveram uma maior instabilidade quando submetidas às mudanças de vazão mas tiveram um melhor desempenho nas vazões mais baixas. Algoritmos de redes neurais artificiais *Perceptron* Multicamadas, *Aprendizagem Profunda* e *Dropout* foram utilizados, tendo o *Dropout* o melhor desempenho com uma estabilidade dos valores de vazão entre -2,6 e 2,3% das faixas e um erro de fundo de escala de 1,8%.

Em ambos os casos, os erros de fundo de escala e erros fiduciais foram plenamente satisfatórios tendo em vista as premissas iniciais deste trabalho. Os resultados obtidos comprovaram a possibilidade de desenvolver um medidor de vazão térmico não intrusivo de líquidos capaz de inferir vazões entre 0.14 e 0.6m³/h com um erro de fundo de escala igual a 1,8%.

No intuito de melhorar os resultados apresentados, sugere-se para trabalhos futuros:

- Criar outros modelos utilizando um maior número de características físicas;
- Testar redes neurais artificiais recorrentes para obter melhores medições;
- Otimizar o posicionamento e número de sensores;
- Estudar os efeitos da validação cruzada sobre outros modelos de redes neurais.

REFERÊNCIAS

AGUIRRE, L.A. *Introdução à Identificação de Sistemas – Técnicas Lineares e Não Lineares Aplicadas a Sistemas Reais*, 3ª ed., Editora UFMG, 2007.

ALBERTAZZI, A. G. Jr.; SOUZA, A. R.. *Fundamentos de Metrologia Científica e Industrial*. 1ª ed., Editora Manole, São Paulo, 2008.

ALTMAN, N. S. An Introduction to Kernel and Nearest-Neighbor Nonparametric Regression, *The American Statistician*, vol. 46, pp. 175-185, 1992.

AMARAL, J. L. M. ; SILVA, J. R. C. ; ANDRADE, D. S. M. ; FERREIRA, L. T. ; QUIRINO, T. M. ; QUIRINO, J. M. . Machine Learning Algorithms Applied to the Inference of the Flow Rate in a Non-intrusive Thermal Flow meter. In: 4th International Symposium on Instrumentation System, Circuits and Transducers, São Paulo, 2019. p. 1-6.

ASHAUER, M., H. GLOSCH, F., HEDRICH, N., HEY, H., SANDMAIER AND W. LANG. 1999. *Thermal flow sensor for liquids and gases based on combinations of two Principles* Sensors and Actuators, 73, pp. 7–13.

ASHER, R. C. Ultrasonic sensors for chemical and process plant. Institute of Physics Pub., 1997.

AWWA. *Flowmeters in Water Supply*. 1ª ed., Denver, American Water Works Association, 1989.

BENGIO, Y. Learning deep architectures for ai. *Foundations and trends® in Machine Learning*, Now Publishers, Inc., v. 2, n. 1, p. 117, 2009.

BIONDI, L. N.; PACHECO, M. A. C.; VELLASCO, M. M. B. R.; PASSOS, E. P. L.; CHIGANER, L.. Sistema Híbrido de Apoio à Decisão para Detecção e Diagnóstico de Falhas em Redes Elétricas. Anais do III Simpósio Brasileiro de Redes Neurais, Recife, p. 197-204, 1996.

BOCCATO, L.; ATTUX, R.. Notas de Aula de Aprendizado de Máquinas: Tópico 5 k-Nearest Neighbors. http://www.dca.fee.unicamp.br/~lbocato/topico_5_k_nearest_neighbor.pdf,

Acesso em 20/04/2020.

BREIMAN, L.; FRIEDMAN J.H.; OLSHEN, R.A. e STONE, C.J., Classification and Regression Trees. *Wadsworth International Group*, Califórnia, 1984.

BRIGGS-SMITH, M.; PISCITELLI, S.; LIVREA, A., "Pulsed thermistor technique for measuring very low liquid flow rates," *Review of Scientific Instruments* , vol.52, no.10, pp.1565,1568, Oct 1981

CASSIOLATO, C.; ALVES, E. O. 2008. *Medição de Vazão*. Controle & Instrumentação v. 138.

CHEN, T.; GUESTRIN, C., XGBoost: a scalable tree boosting system. In: ACM SIGKDD2016, pp.785-794 (2016).

CLOCKER, K.; SENGUPTA, S.; LINDSAY, M.; JOHNSTON, M. L.. "Single-element thermal flow sensor using dual-slope control scheme" in Proc. IEEE Sensors, Oct. 2017, pp. 1–3.

COLANTONIO, R. 2007. *Estudo e implementação de um medidor de vazão eletromagnético para pesquisa na área de circulação assistida*, Dissertação de Mestrado, São Caetano do Sul, Centro Universitário do Instituto Mauá de Tecnologia.

COMSOL. 2017. Disponível em: <<https://br.comsol.com/multiphysics/navier-stokes-equations>>. Acesso em: 15 jun. 2020.

COMSOL. 2018. Disponível em: <<https://br.comsol.com/multiphysics/heat-transfer-conservation-of-energy>>. Acesso em: 15 jun. 2020.

COMTE-BELLOT, G.. Hot wire anemometry. *Annu. Rev. Fluid Mech.*, 8, 209–231, 1976.

CORREIA, P. T. A. 2009. *Automação e Instrumentação*. Engenharia de Dutos, ABSM, Rio de Janeiro, 2009.

DAVE, J. A.; MANERA, A.; Inference of Gas-liquid Flowrate using Neural Networks, Cornell University, arXiv:2003.08182, 2020

DAYHOFF, J. E. *Neural Network Architectures an Introduction*, London, Van Nostrand Reinhold, 1990.

DELMÉE, Gérard Jean. Manual de medição de vazão. 2ª Edição, São Paulo: Edgard Blücher, 1982.

ELONKA, S. M.; PARSONS, A.R.. Manual de Instrumentação., (Standard Instrumentation Questions and Answers), 1a edição, volume 1, São Paulo, Mc Graw Hill do Brasil Ltda., 1976.

ENGELIEN, E.; ECIN, O.; VIGA, R.; HOSTICKA, B.J. ; GRABMAIER, A.; “Calibration-Free Volume Flow Measurement Principle Based on Thermal Time of-Flight (TToF)”, *Procedia Engineering*, Volume 25, pp.765-768, 2011.

ESFE, M. H.; AFRAND, M.; YAN, W.; AKBARI, M.; Applicability of artificial neural network and nonlinear regression to predict thermal conductivity modeling of Al₂O₃–water nanofluids using experimental data, *International Communications in Heat and Mass Transfer*, Volume 66, 2015, Pages 246-249, ISSN 0735-1933.

EVANS, R. P.; *Mass Flow Measurement Through Flow-Induced Pipe Vibration*. Ph.D. Thesis, Idaho State University, Pocatello, 2004.

FAN, Z.; CAI, M.; XU, W. *Non-invasive and non-intrusive gas flow measurement based on the dynamic thermal characteristics of a pipeline*, IOP Publishing Measurement Science and Technology. 2012.

FERRERO, C. A. 2009. *Algoritmo kNN para previsão de dados temporais: Funções de previsão e critérios de seleção de vizinhos próximos aplicados à variáveis ambientais em limnologia*. Dissertação de Mestrado, São Carlos, USP.

FEUERMANN, D.; TAYLOR, H. E; ENGLANDER, S; *Non-intrusive flow measurement by cross-correlation of temperature variations: a tool for building energy diagnostics*, Energy and Buildings, Issue 19, pp. 81 – 86, 1992.

FORTI, M. 2018. *Técnicas de machine learning aplicadas na recuperação de crédito do mercado brasileiro*. São Paulo, FGV.

FREUND, Y.; SCHAPIRE, R. E. et al. Experiments with a new boosting algorithm. In: BARI, ITALY. *Icml*. [S.l.], 1996. v. 96, p. 148–156.

GAMA, J. Árvores de decisão, Disponível em: <https://www.dcc.fc.up.pt/~ines/aulas/MIM/arvores_de_decisao.pdf>. Acesso em: 24 nov. 2019.

GIANNETTI, N.; REDO, M. A.; JEONG, J.; YAMAGUCHI, S.; SAITO, K.; KIM, H. (2020). Prediction of two-phase flow distribution in microchannel heat exchangers using artificial neural network. *International Journal of Refrigeration*, 111, 53-62.

GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. *Deep learning*. Massachusetts: MIT press Cambridge, 2016. v. 1

GREFF, K.; SRIVASTAVA, R. K.; KOUTNÍK, J.; STEUNEBRINK, B. R. & SCHMIDHUBER, J. (2015). LSTM: A search space odyssey. arXiv preprint arXiv:1503.04069.

GRUBELNIK, V.; MARHL, M.. Drop Formation in a Falling Stream of Liquid, *American Journal of Physics*. 73 (5) May 2005, pp. 415-419

HAMMERSCHMIDT, U.; SOSNA, C.; BENKERT, A.; MEIER, A.; VÖLKLEIN, F.. *A Pulsed Thermal-Flow (PTF) Sensor Measures Velocity of Flow and Thermal Difusivity*, Springer Science+Business Media, 2019

HAN M., FAN M., XI J. (2005) Study of Nonlinear Multivariate Time Series Prediction Based on Neural Networks. In: Wang J., Liao XF., Yi Z. (eds) *Advances in Neural Networks*

– ISSN 2005. Lecture Notes in Computer Science, vol 3497. Springer, Berlin, Heidelberg

HANG T. M.; HOWARD D. B.; MARK B.. Neural Network Design. PWS Publishing Company: Beijing, 2002.

HAYKIN, S.. Neural Networks a Comprehensive Foundation, Englewood Cliffs: Macmillan College Publishing Company, 1994.

HOCHREITER, S. & SCHMIDHUBER, J. (1997). Long short-term memory. Neural Comput.,9(8):1735--1780. ISSN 0899-7667.

HOERA, C.; SKADELL, M.M.; PFEIFFER, S.A.; PAHL, M.; SHU, Z.; BECKERT, E. et al., A chip-integrated highly variable thermal flow rate sensor, Sens. Actuators B Chem. 225 (2016) 42–49.

INCONTROL. *Manual de Operação e Instalação: Computador de Vazão Indicador, Totalizador e Transmissor de Vazão Série MEV3000*, INCONTROL S/A, São Paulo, rev. G, 2008.

INCONTROL. *Manual de Operação e Instalação: VTG Medidor de Vazão Tipo Turbina para Gases*, INCONTROL S/A, São Paulo, ver. D, 2009.

INCROPERA, F.P. “Internal Flow,” in *Fundamentals of Heat and Mass Transfer*, 6thed., LTC,2011,pp. 486–502.

JAMES, G. et al. *An Introduction to Statistical Learning*. New York: Springer New York, 2014.

JOHNSON, R. A.; WICHERN, D. W. *Applied Multivariate Statistical Analysis*. 6. ed. New Jersey: Pearson Education, Inc., 2007.

JUNIOR, W.J.A.; 2018. *Métodos de otimização hiperparamétrica: um estudo comparativo utilizando árvores de decisão e florestas aleatórias na classificação binária* Dissertação de Mestrado, Belo Horizonte, UFMG.

KING, L. S. “*Convection of Heat from Small Cylinders in a Stream of Fluid: Determination of the Convection Constants of Small Platinum Wires with Applications to Hot-Wire Anemometry*”, *Phil. Trans. R. Soc. Lond.*, n. 214A, pp. 373–432, 1914.

KUHN, M.; JOHNSON, K. *Applied Predictive Modeling*. New York: Springer, 2013

LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. *nature*, Nature Publishing Group, v. 521, n. 7553, p. 436, 2015.

LEE, H.; BAEK, S., JEON, E., & LEE, J. (2016). Microneedle thermal flow sensor. *2016 IEEE SENSORS*, 1-3.

MATTOS, E. E.; FALCO, R. *Bombas industriais*. 2 ed. Rio de Janeiro: Interciência, 1998.

MEDEIROS, K. A. R.; BARBOSA, C. R. H.; OLIVEIRA, E. C. (2015) *Flow Measurement by Piezoelectric Accelerometers: Application in the Oil Industry*, *Petroleum Science and Technology*, 33:13-14, 1402-1409, DOI: 10.1080/10916466.2015.1044613

MITCHELL T. *Machine Learning*. New York: McGraw-Hill, 1997. 414p.

MOAZZENI, T.; JIAN M.; YINGTAO J., *Measurement and Calibration of Thermal Cross-Correlation-Based Flowmeter Operating in Harsh Environment*, *Instrumentation and Measurement*, *IEEE Transactions on*, vol.62, no.8, pp.2280- 2285, Aug. 2013.

NAGHETTINI, M.; PINTO, E. J. A. *Hidrologia estatística*, CPRM, Belo Horizonte, 2007.

NAJAFI, M.; CULP, C.; LANGARI, R.. *Performance Study of Enhanced Auto-Associative Neural Networks for Sensor Fault Detection*, *Energy Systems Laboratory*, 2004.

NELSON, D. M. Q.; *Uso de redes neurais recorrentes para previsão de séries temporais financeiras*, Universidade Federal de Minas Gerais, 2017.

NGUYEN, Nam-Trung. *Flow Measurement*, 28.9, by CRC Press LLC, 1999.

NNABUIFE, S.G.; PILARIO, K.E.F.; LAO, L.; CAO, Y.; SHAFIEE, M.. Identification of gas-liquid flow regimes using a non-intrusive Doppler ultrasonic sensor and virtual flow regime maps, Elsevier Flow Measurement and Instrumentation 68 (101568), 2019.

OLIVEIRA, M.A.A. 2010. *Desenvolvimento de um Medidor de Vazão Termal Inteligente*, Dissertação de Mestrado, Rio de Janeiro, UERJ/PEL.

PARMEZAN, A. R. S. 2016. *Predição de séries temporais por similaridade*, Dissertação de Mestrado, São Carlos, USP.

PATRA, J. C.; GOPALKRISHNAN, V.; ANG, E. L.; DAS, A.. Neural Network-Based Self-Calibration/ Compensation of Sensors Operating in Harsh Environments. Sensors, 2004. Proceedings of IEEE Volume, Issue, 24-27 Oct. 2004 Page(s): 425 - 428 vol.1.

PEREIRA, J.M. D.; POSTOLACHE, O.; GIRÃO, P. S.. Using a Dual-Channel FDC Device and ANN Techniques to Improve Measurements Accuracy. Sensors & Transducers Magazine (S&T e-Digest),2005, vol.62, Issue 12, pp.462-472.

PIANUCCI, M. N.; PITOMBO, C. S.. Uso de árvore de decisão para previsão de geração de viagens como alternativa ao método de classificação cruzada, CTAC Revista de Engenharia Civil 56, p.5-13, 2019.

PLAKK, P., LIIK, P. AND KINGISEPP, P. H.*Hot-wire anemometer for spirometry*.Med. Biol. Eng. Comput., 1998.p. 17-21.

QUIRINO, T. Q. 2015. *Desenvolvimento de um Medidor de Vazão Não Intrusivo Utilizando Calorimetria Inteligente*, Dissertação de Mestrado, Rio de Janeiro, UERJ.

QUIRINO, T.M.; SOUZA, J.B.;AMARAL, J. L. M.; AMARAL, J.F.M.; OLIVEIRA, M. A. A. *Métodos Inteligentes para Modelagem e Ajuste de um Medidor de Vazão Termal*, Congresso Brasileiro de Automática, Belo Horizonte, 2014.

RACHALSKI, A. 2006. *High-precision anemometer with thermal wave.*, Rev. Sci. Instrum., 77, 095107-1.

RIVERA, J.; CARRILLO, M.; CHACÓN, M.; HERRERA, G.; BOJORQUEZ, G.. Self-Calibration and Optimal Response in Intelligent Sensors Design Based on Artificial Neural Networks. Sensors ISSN 1424-8220, 7, 1509-1529, 2007.

SACHENKO, A.; KOCHAN, V.; TURCHENKO, V.. Intelligent System for Prediction of Sensor Drift. In Proc. of International Workshop on Virtual and Intelligent Measurement Systems, 2000, Annapolis, USA, pp 88-92.

SANTOS, G. H. 2018. *Comparação da performance de algoritmos de machine learning para a análise preditiva em saúde pública e medicina*, Tese de Doutorado, São Paulo, USP.

SAVITSKY, A.; GOLAY, M. J. 1964. *Smoothing and differentiation of data by simplified least squares procedures*, Analytical chemistry 36: 1627–1639

SAZHIN, O. 2013. *Novel mass air flow meter for automobile industry based on thermal flow microsensors. I. Analytical model and microsensors*. Flow Measurement and Instrumentation, 30, 60–65.

SHABAN, H.; TAVOULARIS, S.; 2014. Measurement of gas and liquid flow rates in two-phase pipe flows by the application of machine learning techniques to differential pressure signals. Int. J. Multiph. Flow 67, 106–117

SHEN, D.; WU, G.; SUK, H.-I. Deep Learning in Medical Image Analysis. Annu. Rev. Biomed. Eng. 19, 221–248 (2017)

SILVA, R. P. S. 2017, *Análise de escoamento gás-líquido em tubulações a partir de ECT*, Monografia de Graduação, Joinville, UFSC

SRIVASTAVA, N.; HINON, G.; KRIZHEVSKY, A.; SUTSKEVER, I.; SALAKHUTDINOV, R.. Dropout: A Simple Way to Prevent Neural Networks from Overfitting. Journal of Machine Learning Research, University of Toronto, 2014.

STUCKENBRUCK, S. 2009. *Escoamento de Líquidos e Gases em Dutos*. Engenharia de Dutos, ABSM, Rio de Janeiro, 2009.

VIKRAM, S. A. R.; PAVAN S. Y.; SHRESTHA, M.; UDIT, N.. Deep Air: Forecasting Air Pollution in Beijing, China,2017.

WHITE, F. M. Fluid Mechanics. McGraw-Hill, 4^a ed., 2002.

ZICHUAN, F; MAOLIN, C; WEIQING, X; “Non-invasive and non-intrusive gas flow measurement based on the dynamic thermal characteristics of a pipeline *Meas. Sci. Technol.* **23** 105303, 2012.

Machine Learning Algorithms Applied to the Inference of the Flow Rate in a Non-intrusive Thermal Flow meter

Jorge Amaral, *Member, IEEE*
Dept. of Electronics and Telecomm Eng.
State University of Rio de Janeiro
Rio de Janeiro, Brazil
jamaral@uerj.br

José Rodrigo Castro Silva
Graduate Studies in Electronics Eng.
State University of Rio de Janeiro
Rio de Janeiro, Brazil
rodrigopibf@hotmail.com

Domingos Sávio Mattos de Andrade
Graduate Studies in Electronics Eng.
State University of Rio de Janeiro
Rio de Janeiro, Brazil
d.savio.andrade@gmail.com

Leandro Trindade Ferreira
Dept. of Electronics and Telecomm Eng.
State University of Rio de Janeiro
Rio de Janeiro, Brazil
leandro.lt187@gmail.com

Tiago Motta Quirino
Dept. of Electrical Eng.
Federal University of Juiz de Fora
Juiz de Fora, Brazil
tqmotta@gmail.com

Jonatas Motta Quirino
Dept. of Mechanical Eng.
State University of Rio de Janeiro
Rio de Janeiro, Brazil
quirinojm@hotmail.com

Abstract—This work presents a non-intrusive thermal flow measurement system for small diameters and flow rates. Such a system employs the principle of forced convection. It has a set of six K-type thermocouple type temperature sensors, and a heating resistor installed on the outer surface of a pipe to obtain the thermal distribution as a combined effect of the heating, generated by the resistor, and of the cooling, caused by the internal flow. From the profile of the thermal distribution in the pipe, the inference of the flow rate is investigated by the linear regression model and, later, in a similar way, with different machine learning algorithms such as K nearest neighbors, Decision trees, Random Forest, AdaBoost, and Gradient Boosting. The results showed that it is possible to develop a non-intrusive meter capable of inferring the flow rate with a maximum error of less than 2%.

Index Terms—non-intrusive, flow meter, machine learning, thermal

I. INTRODUCTION

The measurement of the flow rate is present in several human activities, being, for this reason, nowadays it is one of the most measured quantities. The hydrometer of a residence and the fuel pump in a gas station are typical examples in people's daily lives. Besides, it is also present in several industrial and scientific applications such as the control of the receipt of gas or oil in a pipeline, accounting for the total bottled beverage in a soft drink factory, dialysate and ultrafiltrate flow control in dialysis machines and wind speed measurements at weather stations and airports. The wide range of applications, each with different requirements, means that there are several types of meters available which employ different measurement principles. The choice of the meter will depend on the type of fluid (and its physical condition), the

required accuracy, operating range, cost, complexity, readability and service life. The classification of the meters takes into account the disturbance that the transducer element introduces in the measurement. In general, they can be intrusive and non-intrusive. In intrusive meters, the transducer element is in contact with the flow and becomes an obstacle to the fluid, which generates an alteration in the flow. Also, there may be deposition of materials and contamination of the stream, which prevents the use of these meters in some processes, such as in dialysis where the equipment, the tube through which the dialysis solution circulates, is sterile and must be kept in that way throughout the therapy. An example of an intrusive meter is the Venturi, where the flow is related to the differential pressure between the major and minor cross sections of the meter, according to Bernoulli's theorem. In the case of non-intrusive meters, there is no contact between the fluid and the measuring equipment, which provides many advantages compared to intrusive meters such as no obstacle to the liquid, ease of installation and longer life. These advantages have increased interest in non-intrusive meters, with emphasis on magnetic induction and ultrasonic (Doppler or transit time) meters. However, these meters also have some disadvantages. According to the American Water Works Association [1], magnetic meters can only be used with liquids having minimum conductivity of $200\mu S/m$, and for small diameter pipes, it becomes large and expensive. In the case of meters using ultrasound, those using the Doppler effect depending on the reflection of ultrasound waves in the particles suspended in the fluid. On the other hand, the meters that estimate the flow rate by the difference in the transit time have difficulty to make measurements in small diameters. An alternative is thermal convection flow measurement, based on the refrigerant effect of a fluid passing over a heated transducer. This technique is

The authors would like to acknowledge the financial support provided by FAPERJ (Jovem Cientista do Nosso Estado and PROCIENCIA programs) and CAPES - Finance Code 001.

indicated, above all, in applications where it is necessary to measure small flow rates. Thermal flow meters rely on the relationship between heat transfer and mass transport, based on the principle of forced convection in a flow channel and therefore the measurement can be performed non-intrusively. According to the organization of the sensor components and thermal actuators, it is possible to discriminate thermal flow meters into four main categories: calorimetric, time-of-flight (TOF), thermal anemometers and thermal oscillation. The calorimeter principle is based on changing the temperature profile, next to the heater element, by the flow of fluid. The asymmetry characteristics, concerning heating, of the thermal profile in the presence of the flow can be used to infer the flow rate [2]. This work presents the preliminary results of a non-intrusive thermal flow meter for small flow rates ($0.05 \text{ m}^3/\text{h}$ to $0.6 \text{ m}^3/\text{h}$, in small diameters (25mm) using the calorimeter principle. From the measurements of the temperature profile in a heated tube, several machine learning models were set to perform flow rate inference.

II. THERMAL FLOW METERS

Thermal flow meters rely on the relationship between heat transfer and flow mass transport, based on the principle of forced convection in a flow channel, and therefore the measurement can be performed non-intrusively. According to the organization of the sensor components and thermal actuators, the thermal flow meters can be divided into four main categories: time of flight (TOF), thermal anemometers, thermal oscillation and calorimetric [2], [3], [4], [5]. The method used to measure the velocity of the fluid by TOF is to determine the time delay of the thermal pulse. The heater generates a heating pulse, and after some time (flight time) temperature sensors located downstream of the fluid flow perceive the pulse. The time delay has a close relationship with the fluid velocity [3], [4]. Thermal anemometers are among the most common flow meters. An electrically heated element cools as a result of heat exchange with the fluid. Thus, it is possible to determine the flow rate by determining the amount of heat transferred from the heater to the fluid [5]. Thermal oscillation is another measuring technique that requires only the heating element and a thermal sensor coupled to the tube. A heating pulse is applied to cause the sensor temperature to be changed. Then, the time required for the cooling, to a preset temperature value, is measured. When this value is reached, a new temperature pulse is emitted, and so the process repeats itself. In this sense, an oscillatory behavior appears in the temperature measurement and a train of pulses generated in the heater. By the frequency of the pulse train, it is possible to determine the flow rate. The calorimeter type flow meters are based on the alteration of the temperature profile, next to the heater element, due to the flow of fluid. The temperature profile is generated by conducting heat, by thermal dispersion in the material of the tube around a heating element, and by the convective heat exchange of a fluid traveling through the tube. To use such a principle, it is necessary to have a heater and several thermal sensors. The conduction of the heat supplied

by the heating (Q) in the fluid, without flow, and in the wall of the tube results in the spatial distribution of temperatures sketched and indicated in Fig. 1. When the fluid is in motion, and the heating is maintained the convective effect and the change in the temperature distribution is related to the flow (\dot{m}), as also indicated in Fig. 1. If one considers that the temperature of the fluid smaller than that of the heated tube, the change in the profile occurs due to the decrease of the temperature of the tube in the inlet region, upstream of the heater, while at the same time, there is a consequent increase in temperature of the fluid. As the mass of fluid continues to move through the tube, the cooling is smaller because the temperature difference between the liquid and the tube decreases. Downstream of the heater, it is possible that the fluid will heat the pipe which can further reduce the cooling effect along the canal. The lower is the flow rate; less mass of fluid receives heat from the tube in a given period. In the first contact regions, the cooling occurs rapidly, but in the following areas, the fluid mass is already heated and is not able to cool the tube, so in the upstream region, the thermal exchange is much more intense than in the region downstream, causing a significant disparity in the profile. In the case of higher flow intensity, the fluid has more mass for thermal exchange, for a while, so the cooling of the inlet region slightly modifies the temperature of the liquid and consequently causes a more uniform cooling along the tube.

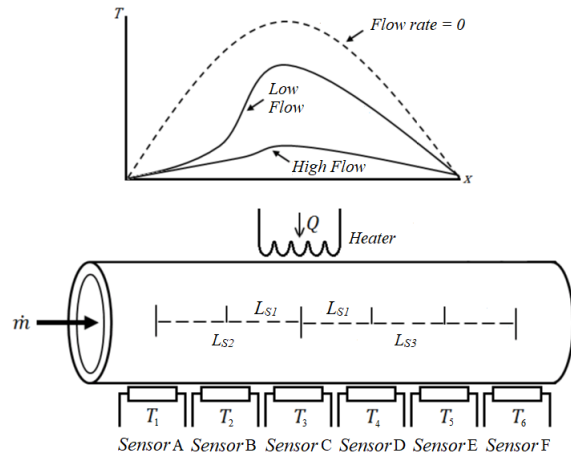


Fig. 1. Calorimeter type flow meter and the temperature profile.

A. Related Works

Several works demonstrate the possibility of using different measuring techniques using the thermal principle both intrusively and non-intrusively. For the intrusive case, one can mention the work of Smith & Piscitelli [6]. They developed an intrusive flow sensor to monitor the perfusion in surgeries. This device can measure meager flow rates (2-20ml/min) and is based on the thermal oscillation technique which is applied to a thermistor to generate an oscillatory behavior at

its temperature, which in turn makes the frequency of this oscillation is proportional to the flow rate being measured. Arirav and his collaborators [7] investigate different techniques of digital processing in the design of thermal flow meters. The proposed arrangement consists of one of a heat source (heated nickel-chromium wire) and a temperature sensor (thermistor) placed at a given distance. The delay between the heat source temperature signal and the thermistor, known as “flight time”, can be used to determine the velocity of the flow. Two models were investigated, and a delay model was the one most compatible with the experimental data. Moazzeni and his colleagues [8] developed a fluid flow meter based on cross-correlation for use in nuclear reactors. The flow rate can be obtained by estimating the delay between two correlated thermal signals obtained through two thermocouples placed along the duct and separated by a predetermined distance. Although in theory, this method is simple, there are several challenges in signal processing such as the existence of plateaus or multiple peaks. A flow meter based on the thermal “flight time” for gases, liquids, and mixtures is presented in [9]. Flight time is measured using a heat source to inject pulses of heat into the pipeline line through which the fluid travels, and three sensors, positioned after the heat source, which detect the heat gradients. Through the correlation of the signals of the sensors, the velocity can be inferred. The main advantage of this type of sensor is that it does not depend on the properties of the fluid and can be used for liquids, gases or even mixtures. In the case of non-intrusive thermal flow meters, the work of Feuermann and his collaborators [10] presents a non-intrusive water meter in which the flow is obtained by correlating two time series of temperature, which is measured on the outer surface of the tube. The reported accuracy of the method is around 10% with a maximum error of 16%. This accuracy, according to the authors, is similar to other instruments commonly used in audits to identify problems in the distribution of heating in buildings. Another example of a non-intrusive gas meter can be seen in [11]. A heat source is fixed to the outer wall of the duct and emits thermal pulses by default. Two sensors are also placed on the exterior wall will detect the temperature shift in the direction and in opposite the course of the gas. The relationship between the gas and the dynamic thermal characteristics of the fluid determine the gas flow rate. However, according to the authors themselves, the results are “approximately acceptable” and modifications are needed to improve the accuracy of the method. In the related works described here, it is observed that thermal flow measurement has attracted a great deal of interest either because of the possibility of being applied in a wide variety of applications because of the difficulty of adopting other methods of flow measurement [10] cost and simplicity [9], [6], for their reliability and robustness [8], especially regarding low flow rates. However, the thermal principle still presents a series of challenges for both intrusive and non-intrusive methods. Among the main difficulties we can mention: The great dependence of the fluid properties sensor [9]; of the difficulty of performing the physical modeling [7]; to predict

system behavior through numerical simulations [11]; of the need to use relatively complex digital processing techniques [8]. This scenario suggests that there is open space for the investigation and development of new techniques of non-intrusive measurement by the thermal principle.

III. MEASUREMENT SYSTEM PROTOTYPE

Fig. 2 shows the test bench required to evaluate the performance of the flow measurement system prototype. It contains a tank (TQ1) with controlled temperature, which serves as a reservoir that allows the recirculation of the liquid. The TQ1 temperature control will be performed by Labview (KU1) through the electric resistance (KB1), the agitator (AG1) and the TP1 thermocouple. The heating resistor (KBMVT) is located in the center of the sensor tube, and the six type K thermocouples are in charge of measuring the temperature sensors along the sensor tube. A PID controller that is implemented in Labview (KU1) ensures that the center of the sensor tube is at a constant temperature. According to the temperature provided by the thermocouple C, which is located in the center of the tube, KU1 varies the pulse width of a PWM which in turn controls the voltage supplied to the heating resistor through a solid state relay. Similarly, the flow rate control of the pump is performed by another PID controller which uses the non-intrusive electromagnetic flow meter (FIT1) as a reference. The output of the PID controller is connected to another PWM that controls the operation of a water pump (24V, 4.5A, 0.68 m^3/h). Valves VH1 and VH3 are positioned for easy cleaning and maintenance of the tank. FV-01 is a proportional control valve that can be used to implement a refined flow rate control, if necessary. Fig. 3 shows a photo of the test bench constructed (with an inside view of the flow meter). A program in G language (Labview) is responsible for the control of the experiments in the test bench.

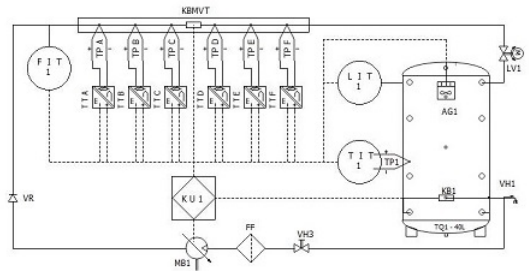


Fig. 2. Diagram of the measuring system prototype.

IV. MACHINE LEARNING ALGORITHMS

The choice of the appropriate machine learning algorithms is an essential step in this study. One commonly used approach is to pick different representative algorithms. Therefore, to perform the experiments, the following algorithms were selected: Linear regression, linear regression with L1 norm penalty (LASSO), decision trees and k nearest neighbor. Also, to experiment with ensemble techniques, three algorithms were



Fig. 3. The measuring system prototype and close view of the thermal flow meter.

included: Random Forests, Adaboost and Gradient Boost. The brief description of the algorithms is here, and a complete explanation is available in the References. Linear Regression (LR) is a straightforward approach in supervised learning. It assumes that the relationship between the dependent variable and the explanatory variables (also called independent variables) is linear. Therefore, the relationships are modeled using linear predictor functions whose unknown model parameters are estimated from the training data. Linear regression models are often fitted by minimizing a least squares cost function, or a penalized version of the least squares cost function as in ridge regression (L2-norm penalty) and lasso (L1-norm penalty) [12]. The K nearest neighbor regressor (KNNR) is one of the most elegant and straightforward methods in Machine Learning [13]. It is a type of instance-based learning, or lazy learning, which means that in the learning stage, it merely stores a set of input-output pairs (training set). When an output for a new query instance has to be determined, the algorithm finds K number of training instances closest to the query point, using a similarity function usually based on the Euclidean distance. Then it performs local interpolation of the targets associated with the nearest neighbors. A Decision Tree Regressor (DTR) is a hierarchical structure that consists of nodes and branches [12]. There are three types of nodes: the root that has only outgoing branches, the internal nodes that have one incoming and two or more outgoing branches

and terminal (leaf) nodes that have no outgoing branches. All terminal nodes have a value of the output assigned to them. Each non-terminal node in the tree represents a test on one of the attributes, and each branch that comes out of the node represents one of the possible outcomes of the test performed. The output value for a query instance is obtained by starting at the root node, testing the attribute specified by this node, and then moving down the tree branch corresponding to the outcome of the test for this attribute. This process is repeated until it gets to a terminal node, where the output value is given to the query instance which is simply the mean of the output values for the training observations that would also have reached the same terminal node. Random Forests is an ensemble learning method that produces and combines several decision trees [14]. When Random Forest is employed for regression (RFR), it presents the average of the individual tree's results. It can handle a vast number of input variables and offers an internal estimation of the generalization error as forest-building progress. Another essential feature is the ability to construct variable importance plots. AdaBoost Regressor (ADABR) is a suitable boosting method that can assist the user in combining different "weak learner" into a single "strong learner" [15]. AdaBoost can be applied to any learner algorithm; therefore, it builds on top of other learners rather than being a learner itself. It has two characteristics that are essential for satisfactory performance. The first is that it guides the choice of the training set of the new regressor you intend to add, based on the results of the previous regressor. The second is that it helps in determining how much weight should be assigned to each learner to improve the overall performance when combining them. Each weak learner is trained on a random subset of the entire training set. Then, AdaBoost assigns a "weight" to each training example, which determines the probability that each instance should show up in the training set. Therefore, higher weights examples are more often present in the training set. After training a learner, AdaBoost increases the weight on the samples with more top prediction error; as a result, these cases will have a higher chance to be present in the next learner training set, and the following learner will be trained to perform better on these cases. Once the training process is complete, each learner is associated with a weight related to its performance. The higher the performance is, the greater the value of the weight to be assigned. The final classification is obtained by a linear combination of the weak learner. Friedman developed a framework called Gradient Boosting Machines [16] It can be used for classification or regression (GBR). This framework places boosting as a mathematical optimization problem where the goal is to minimize a cost function by adding weak learners using a procedure such as a gradient descent. Gradient Boosting is composed of three main elements: a cost function to be optimized; A weak model to make predictions; An additive model to add a weak learner to minimize the cost function. The cost function depends on the problem to be solved. For example, for regression, the mean squared error is customarily used. Decision trees are used as weak models

in gradient boosting and the additive strategy employed adds one tree at a time, and the previous trees are not modified. A gradient descent procedure is used to minimize the cost function when trees are appended.

V. EXPERIMENTS

The process of determining the flow rate has the following steps: acquisition of data by an experimental procedure, the regression strategies, and analysis of the results obtained. A Labview program controls the experimental procedure. It is in charge of the control the actuators, receives and stores the temperature gauge data by executing the following commands:

- 1) The temperature control of Tank TQ1 is activated to maintain the temperature of the fluid at the desired value for the experiment, in this case, the chosen value was 25°C;
- 2) Initial activation of the sensor tube heating resistor and the temperature control action. Through the PID controller, the temperature in the center of the sensor tube must be maintained at a predetermined value of 70°C;
- 3) After stabilizing the temperature of the heating resistor, the pump is switched on at the highest flow rate to be measured;
- 4) The stabilization of the temperature profile is awaited;
- 5) All profile temperatures are measured so that the temperature and flow rate data are stored;
- 6) The flow rate is changed to a new value to allow the execution of a new measurement ;

Fig. 4 shows the flow and temperature values of each sensor. The picture did not present the temperature value of the C thermocouple because it is used only to perform the temperature control of the center of the sensor tube. It is possible to observe the dependence of temperature and flow, which is higher for thermocouples E and F. One can also witness the effect of heating the water due to the recirculation of the liquid.

The experimental procedure generated a total of 21,413 measurement points for the data set to be processed. Since the size of the dataset is very large, it is safe to adopt the Hold out to train the machine learning models. In this procedure, the available data is divided into training and test datasets. The regressor is trained with the training data set, and the performance of the trained classifier on the test data set allows the estimation of the generalization error. The experiments employed 70% of the dataset as the training data set, and the remaining 30% formed the test dataset. K-fold cross-validation was used only on the training data to decide which algorithms are best suitable for this problem. It allows us to estimate the performance of the learned model from available data using one algorithm. In other words, it is possible to assess its performance in unseen examples (the generalization capability of the algorithm). As a result, it can also be used to compare the performance of two or more different algorithms and realize the best algorithm for the available data. The results of the application of the 10-fold cross-validation only on the

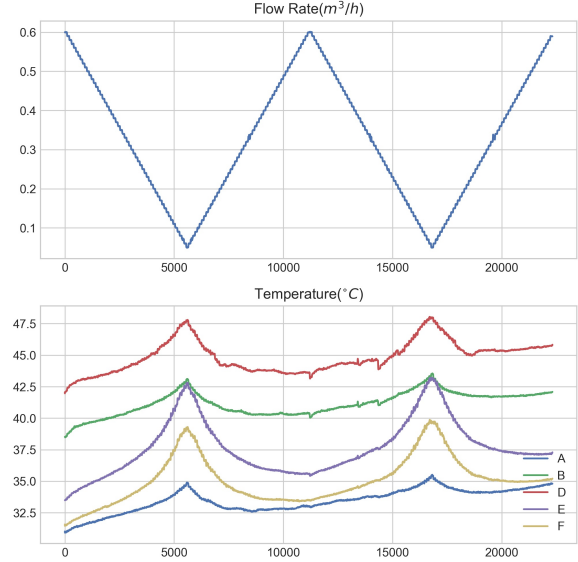


Fig. 4. Flow Rate and Temperature profile.

training data have revealed that more suitable algorithms are: DTR, KNNR, RFR and GBR with the mean squared error (MSE), respectively, equal to 4.0×10^{-6} , 1.0×10^{-6} , 3.0×10^{-6} and 4.2×10^{-5} . All the code for the regression is done in Python 3.6 using scikit-learn library version 0.19.1 [17]. The next step is the search for the best tuning parameters. To find the best tuning settings, it is a good practice to perform a grid search to try a set of different parameters. In the K nearest neighbor regressor, the parameter is the number of neighbors; therefore, each odd k values from 3 to 21 is evaluated using 10-fold cross-validation in the training dataset. A similar procedure is employed to tune the other algorithms; the only difference is the parameter to be optimized. Once the best settings were found the models were trained with the whole training dataset and the generalization error was obtained in the test dataset. Table 1 shows the results of the tuned models. The Linear Regression did not achieve good performance, which indicates a nonlinear behavior in the relationship between the temperature profile and the flow rate. The RFR, although it did not provide the best results, it has a capability of identifying the best input attributes. The RFR has indicated that the more suitable inputs are thermocouples A and E. Further investigation revealed that the temperature measured by the thermocouple A has the highest linear correlation with the fluid temperature (0.78) and the temperature measured by E has the high correlation with the flow rate (0.83). When the RFR is trained with only these inputs, the results improved and the maximum error decreases to 4.4%. KNNR and GBR obtained the smallest maximum errors, respectively, 1.7% and 3.48%. This error is defined as

the percentage of the maximum error divided by the maximum flow rate measured.

TABLE I
RESULTS OF THE TUNED MODELS

Algorithm	Best Parameter	MSE	Max Error (%)
LR	N/A	7.7×10^{-4}	20.4
KNNR	Num_neighbors =3	3.4×10^{-7}	1.7
DTR	Depth=17	4.4×10^{-6}	11.6
RFR	Num_estimators = 400	2.3×10^{-6}	6.55
RFR *	Num_estimators = 400	1.1×10^{-5}	4.43
GBR	Num_estimators = 400	1.5×10^{-5}	3.48

VI. CONCLUSION

This work presented the first results of a non-intrusive flow meter that is more suitable for small flow values and pipe diameters. A prototype of the measurement system and the test bench needed to perform the experiments were built. From the experimental data, several models of machine learning were adjusted, with the best models being: K nearest neighbors and Gradient Boosting, with maximum errors of 1.7% and 3.48%. Although Random Forest has not presented the best result, it has the characteristic of determining the most useful input variables, which suggests a more in-depth investigation regarding the selection and extraction of attributes for the other models. For the future work, it is intended to reduce the diameter of the sensor tube, to deepen the investigation related to the engineering of attributes considering not only the selection of the most relevant variables but also to obtain new features through transformations of the original variables. Finally, it is also intended to use deep learning neural networks Machine Learning Methods applied to the inference of the flow of a non-intrusive meter by the thermal effect to perform the prediction of flow rate values.

VII. ACKNOWLEDGMENT

The authors thank Everton Silva for his invaluable help in the building of measurement system prototype.

REFERENCES

- [1] A. W. W. Association, Ed., *Flowmeters in water supply*, 2nd ed., ser. AWWA manual. Denver, CO: American Water Works Association, 2006, no. M33, oCLC: ocm70660261.
- [2] O. Sazhin, "Novel mass air flow meter for automobile industry based on thermal flow microsensor. I. Analytical model and microsensor," *Flow Measurement and Instrumentation*, vol. 30, pp. 60–65, Apr. 2013. [Online]. Available: <https://linkinghub.elsevier.com/retrieve/pii/S0955598613000125>
- [3] M. Ashauer, H. Glosch, F. Hedrich, N. Hey, H. Sandmaier, and W. Lang, "Thermal flow sensor for liquids and gases based on combinations of two principles," *Sensors and Actuators A: Physical*, vol. 73, no. 1-2, pp. 7–13, Mar. 1999. [Online]. Available: <https://linkinghub.elsevier.com/retrieve/pii/S0924424798002489>
- [4] M. Elwenspoek, "Thermal flow micro sensors," in *CAS '99 Proceedings. 1999 International Semiconductor Conference (Cat. No.99TH8389)*, vol. 2. Sinaia, Romania: IEEE, 1999, pp. 423–435. [Online]. Available: <http://ieeexplore.ieee.org/document/810580/>
- [5] T. M. Quirino, J. B. Souza, J. Amaral, J. Amaral, and M. de Oliveira, "Computation intelligent methods applied for modeling and adjustment of a thermal flow meter," *Int. J. Mech. Eng. Autom.*, vol. 2, no. 3, pp. 127–134, 2015.

- [6] M. Briggs-Smith, S. Piscitelli, and A. Livrea, "Pulsed thermistor technique for measuring very low liquid flow rates," *Review of Scientific Instruments*, vol. 52, no. 10, pp. 1565–1568, Oct. 1981. [Online]. Available: <http://aip.scitation.org/doi/10.1063/1.1136469>
- [7] Y. Avirav, H. Guterman, and S. Ben-Yaakov, "Implementation of digital signal processing techniques in the design of thermal pulse flowmeters," *IEEE Transactions on Instrumentation and Measurement*, vol. 39, no. 5, pp. 761–766, Oct. 1990. [Online]. Available: <http://ieeexplore.ieee.org/document/58622/>
- [8] T. Moazzeni, J. Ma, and Y. Jiang, "Measurement and Calibration of Thermal Cross-Correlation-Based Flowmeter Operating in Harsh Environment," *IEEE Transactions on Instrumentation and Measurement*, vol. 62, no. 8, pp. 2280–2285, Aug. 2013. [Online]. Available: <http://ieeexplore.ieee.org/document/6514056/>
- [9] E. Engelen, O. Ecin, R. Viga, B. Hosticka, and A. Grabmaier, "Calibration-Free Volume Flow Measurement Principle Based on Thermal Time-of-Flight (TToF)," *Procedia Engineering*, vol. 25, pp. 765–768, 2011. [Online]. Available: <https://linkinghub.elsevier.com/retrieve/pii/S187705811058577>
- [10] D. Feuermann, H. E. Taylor, and S. Englander, "Non-intrusive flow measurement by cross-correlation of temperature variations: a tool for building energy diagnostics," *Energy and Buildings*, vol. 19, no. 2, pp. 81–86, Jan. 1992. [Online]. Available: <https://linkinghub.elsevier.com/retrieve/pii/037877889290001W>
- [11] Z. Fan, M. Cai, and W. Xu, "Non-invasive and non-intrusive gas flow measurement based on the dynamic thermal characteristics of a pipeline," *Measurement Science and Technology*, vol. 23, no. 10, p. 105303, Oct. 2012. [Online]. Available: <http://stacks.iop.org/0957-0233/23/i=10/a=105303?key=crossref.9f7fc9146684f09fce1c72cf54bede16>
- [12] T. Hastie, R. Tibshirani, and J. Friedman, *The Elements of Statistical Learning*, ser. Springer Series in Statistics. New York, NY: Springer New York, 2009. [Online]. Available: <http://link.springer.com/10.1007/978-0-387-84858-7>
- [13] L. I. Kuncheva, *Combining pattern classifiers: methods and algorithms*. John Wiley & Sons, 2004.
- [14] L. Breiman, "Random forests," *Machine learning*, vol. 45, no. 1, pp. 5–32, 2001.
- [15] R. E. Schapire, "Explaining adaboost," in *Empirical inference*. Springer, 2013, pp. 37–52.
- [16] J. H. Friedman, "Stochastic gradient boosting," *Computational Statistics & Data Analysis*, vol. 38, no. 4, pp. 367–378, Feb. 2002. [Online]. Available: <http://linkinghub.elsevier.com/retrieve/pii/S0167947301000652>
- [17] F. Pedregosa, G. Varoquaux, A. Gramfort, V. Michel, B. Thirion, O. Grisel, M. Blondel, P. Prettenhofer, R. Weiss, V. Dubourg, J. Vanderplas, A. Passos, D. Cournapeau, M. Brucher, M. Perrot, and E. Duchesnay, "Scikit-learn: Machine Learning in Python," *Journal of Machine Learning Research*, vol. 12, pp. 2825–2830, 2011.