

UNIVERSIDADE DO VALE DO RIO DOS SINOS - UNISINOS
UNIDADE ACADÊMICA DE PESQUISA E PÓS-GRADUAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA
NÍVEL MESTRADO PROFISSIONAL

ESMAEL DE OLIVEIRA FLORES

**DESENVOLVIMENTO DE UM SENSOR POR SOFTWARE PARA O
MONITORAMENTO DA CONCENTRAÇÃO DE PARTÍCULAS EM SALAS LIMPAS.
ESTUDO DE CASO: INSTITUTO ITT CHIP/UNISINOS**

São Leopoldo
2020

Esmael de Oliveira Flores

**DESENVOLVIMENTO DE UM SENSOR POR SOFTWARE PARA O
MONITORAMENTO DA CONCENTRAÇÃO DE PARTÍCULAS EM SALAS
LIMPAS. Estudo de caso: Instituto itt Chip/UNISINOS**

Dissertação apresentada como requisito parcial
para obtenção do título de Mestre em Engenharia
Elétrica, pelo Programa de Pós-Graduação em
Engenharia Elétrica da Universidade do Vale do
Rio dos Sinos - UNISINOS

Orientador: Prof. Dr. Rodrigo Ivan Goytia Mejia

São Leopoldo

2020

F634d

Flores, Esmael de Oliveira.

Desenvolvimento de um sensor por software para o monitoramento da concentração de partículas em salas limpas : estudo de caso : Instituto itt Chip/Unisinos / Esmael de Oliveira Flores. – 2020.

120 f. : il. ; 30 cm.

Dissertação (mestrado) – Universidade do Vale do Rio dos Sinos, Programa de Pós-Graduação em Engenharia Elétrica, 2020.
“Orientador: Prof. Dr. Rodrigo Ivan Goytia Mejia.”

1. Sensores por software. 2. Otimização. 3. Filtro de Kalman.
4. Salas limpas. 5. Monitoramento de partículas. I. Título.

CDU 621.3

Dados Internacionais de Catalogação na Publicação (CIP)
(Bibliotecária: Amanda Schuster – CRB 10/2517)

Esmael de Oliveira Flores

DESENVOLVIMENTO DE UM SENSOR POR SOFTWARE PARA O MONITORAMENTO
DA CONCENTRAÇÃO DE PARTÍCULAS EM SALAS LIMPAS.

Estudo de caso: Instituto itt Chip/UNISINOS

Dissertação apresentada como requisito parcial para
obtenção do título de Mestre em Engenharia Elétrica,
pelo Programa de Pós-Graduação em Engenharia
Elétrica da Universidade do Vale do Rio dos Sinos -
UNISINOS

Aprovado em:

BANCA EXAMINADORA

Prof. Dr. Cesar David Paredes Crovato - UNISINOS

Prof. Dr. Cleiton Bittencourt da Porciúncula – UERGS

Dr. Willyan Hasenkamp Carreira – HT Micron Semicondutores S.A. (Suplente)

Orientador: Prof. Dr. Rodrigo Ivan Goytia Mejia

Visto e permitida a impressão
São Leopoldo,

Prof. Dr. Paulo Ricardo da Silva Pereira
Coordenador PPG em Engenharia Elétrica

AGRADECIMENTOS

Esse trabalho foi desenvolvido ao longo dos últimos dois anos, recebendo inúmeras contribuições que não podem deixar de serem agradecidas, de diversas pessoas, sendo algumas delas aqui citadas:

A minha família, em especial minha noiva Claudia que sempre me incentivou, desde o início, na inscrição para o curso e me dando forças para continuar superando, etapa por etapa, todos os obstáculos para a obtenção do tão sonhado título.

A todos os colegas do mestrado, em especial a Cristian Figueiredo e Tiago Pereira, por compartilharem conhecimento acerca do sistema HVAC das salas limpas que adquiriram no decorrer do desenvolvimento de seus trabalhos finais.

A UNISINOS e todos os seus professores que contribuíram para o meu desenvolvimento, em especial ao meu orientador, professor Dr. Rodrigo Mejia, pela disposição que sempre apresentou em ajudar não apenas com palavras de incentivo, mas também com ideias, por vezes mirabolantes, mas que serviram de inspiração para a escolha dos caminhos tomados até a conclusão deste trabalho.

Ao ITT Chip, em especial ao professor Celso Peter, por sua dedicação ao projeto provendo os recursos necessários e disponibilidade para esclarecimento de dúvidas.

RESUMO

Existe um potencial significativo de economia de energia nos sistemas de climatização ou HVAC (*Heating, Ventilation, and Air Conditioning*) de salas limpas. Importantes componentes desses sistemas, os insufladores recirculam ar ultra limpo constantemente e por esse motivo são um dos ativos que demandam grandes quantidades de energia. Diversas publicações relatam que a vazão de ar em salas limpas costuma ser projetada acima do valor necessário. Paralelamente, estudos publicados propõem modelos de estimação da concentração de partículas em salas limpas, considerando diversas características operacionais. Neste trabalho é proposta uma nova abordagem, onde a vazão de ar (número de trocas de ar por hora) pode ser estimada e fornecida ao ambiente controlado conforme a demanda, gerando uma economia de energia através da redução da velocidade do insuflador, por meio de um sensor por *software*, composto por um modelo de estimação de concentração de partículas no interior de uma sala limpa. São utilizadas duas tecnologias de sensores por *software* para atingir o objetivo proposto: a primeira por meio de um modelo de estimação com correção de parâmetros através de otimização não-linear com restrições, enquanto a segunda utiliza filtro de Kalman para realizar a estimação, inclusive com ruído de medição. Como estudo de caso, foi utilizada uma das salas limpas do instituto itt-Chip da Unisinos. Os resultados revelaram que é possível, sob certas condições e cenários de utilização da sala, uma redução de até 75,6% na energia consumida pelo insuflador do sistema HVAC.

Palavras-chave: sensores por *software*, otimização, filtro de Kalman, salas limpas, monitoramento de partículas, HVAC, eficiência energética.

ABSTRACT

There is a significant potential for energy savings in cleanroom air conditioning or HVAC (Heating, Ventilation, and Air Conditioning) systems. Important components of these systems, insufflators, or fans, which recirculate clean air constantly and for this reason are assets that demand high energy costs. Several publications report that the airflow in cleanrooms is usually projected above the required value. At the same time, several published studies propose models for estimating particle concentration in cleanrooms, considering several operational characteristics. In this work, a new approach is proposed, airflow (air change per hour) is estimated and supplied to the controlled environment according to demand, generating energy savings by reducing fan speed. This technique uses a softsensor composed of a cleanroom particle concentration estimation model. Two softsensors technologies are used to achieve the proposed objective: the first one uses an estimation model with parameter correction through non-linear optimization with restrictions, while the second uses a Kalman filter estimator, even with measurement noise. As a case study, one of the cleanrooms of Unisinos itt-Chip Institute was used. The results revealed that under certain conditions and scenarios of room use, it is possible to reduce up to 75,6% of the energy consumed by the HVAC system fan.

Keywords: softsensors, optimization, Kalman filter, cleanrooms, particle monitoring, HVAC, energy efficiency.

LISTA DE FIGURAS

Figura 1 - Conceito básico de um sensor por <i>software</i>	21
Figura 2 – Sensor por <i>software</i> inserido na malha de controle do processo	22
Figura 3 - Etapas de desenvolvimento de um sensor por <i>software</i> tipo caixa preta..	24
Figura 4 – Etapas de desenvolvimento de um sensor por <i>software</i> tipo caixa branca	24
Figura 5 – Os três pilares básicos de um sensor por <i>software</i>	25
Figura 6 - Exemplo de correlação entre duas variáveis	27
Figura 7 - Exemplo de correlação de uma variável	27
Figura 8 – Fluxos de ar em salas limpas	42
Figura 9 – Esquema típico de um sistema HVAC	43
Figura 10 – Fatores que influenciam na concentração de partículas	45
Figura 11 – Pirâmide das partículas: Relação inversa entre massa e quantidade	47
Figura 12 – Contador de partículas óptico	48
Figura 13 - Métodos de construção de modelos de sensor por <i>software</i>	54
Figura 14 – Características que influenciam na qualidade do ar em salas limpas	62
Figura 15 – Configuração básica do fluxo de ar em salas limpas	67
Figura 16 – Configuração das salas limpas do instituto itt Chip da UNISINOS.....	72
Figura 17 – Contador de partículas Airys P611	74
Figura 18 – Contador de partículas Alphasense OPC R1	75
Figura 19 – Ambiente controlado montado na sala limpa	76
Figura 20 – Microcontrolador para acionar os ventiladores no ambiente controlado	77
Figura 21 – Resultado da simulação do modelo de estimação de concentração de partículas em 4 cenários diferentes.....	79
Figura 22 – Resultado da simulação do modelo para uma faixa de valores de taxa de troca de ar por hora considerando a sala em repouso	80
Figura 23 – Resultado da simulação do modelo para uma faixa de valores de taxa de troca de ar por hora considerando 2 pessoas e 1 máquina	81
Figura 24 – Resultado da simulação do modelo para encontrar a maior taxa de ocupação com $n = 8$	81
Figura 25 – Resultado da simulação do modelo para 4 diferentes cenários	82

Figura 26 – Comparação entre valores medidos e estimados pelo modelo.....	84
Figura 27 – Estrutura do sensor por <i>software</i>	86
Figura 28 – Comparação entre valores medidos e estimados pelo modelo.....	89
Figura 29 – Valores dos parâmetros após seus ajustes propiciados pela otimização	89
Figura 30 – Sinal de erro do modelo antes e após o ajuste dos parâmetros	90
Figura 31 – Comparação entre valores medidos e estimados pelo modelo.....	91
Figura 32 – Estrutura do sensor por <i>software</i> com correção de parâmetros.....	92
Figura 33 – Estrutura do sensor por <i>software</i> com filtro de Kalman.....	94
Figura 34 – Resultado do sensor por <i>software</i> com filtro de Kalman para 4 cenários diferentes.....	99
Figura 35 – Contador de partículas óptico Lighthouse Remote 5012.....	99
Figura 36 – Proposta de redução de trocas de ar por hora e seu impacto no consumo de energia do insuflador	102
Figura 37 – Queda da pressão na sala limpa em função do tempo devido ao acúmulo de partículas nos filtros	105

LISTA DE TABELAS

Tabela 1 - Norma NBR ISO 14644.....	38
Tabela 2 - Classificação de salas limpas de acordo com a NBR ISO 14644-1	39
Tabela 3 – Partículas geradas por indivíduo em função do tipo de atividade	41
Tabela 4 – Partículas geradas por indivíduo em função do vestuário.....	41
Tabela 5 – Parâmetros típicos de sistemas HVAC em salas limpas	44
Tabela 6 - Trabalhos com sensor por <i>software</i> que utilizam modelos fenomenológicos, além de empíricos baseados em Redes Neurais.....	56
Tabela 7 - Trabalhos com sensor por <i>software</i> que utilizam modelos empíricos baseados em métodos de regressão	57
Tabela 8 – Recomendações de trocas por hora de ar em salas limpas.....	60
Tabela 9 – Estudos e produtos que abordam concentração de partículas e economia de energia	65
Tabela 10 – Comparação entre os 3 modelos de estimação de concentração de partículas.....	68
Tabela 11 – Parâmetros de projeto das salas limpas do itt Chip.....	73
Tabela 12 – Avaliação estatística da qualidade do modelo.....	85
Tabela 13 – Avaliação estatística do modelo após ajuste dos parâmetros	91
Tabela 14 – Taxa de trocas de ar mínima para cada cenário de utilização da sala mantendo a concentração de partículas máxima permitida em norma	102

LISTA DE SIGLAS

ABNT	Associação Brasileira de Normas Técnicas
ANN	<i>Analytical Neural Network</i>
CEKF	<i>Constrained Extended Kalman Filter</i>
DCF	<i>Demand-Controlled Filtration</i>
EKF	<i>Extended Kalman Filter</i>
KF	<i>Kalman Filter</i>
HVAC	<i>Heating Ventilation, and Air Conditioning</i>
ICA	<i>Independent Component Analysis</i>
ICCS	<i>Intelligent Cleanroom Control System</i>
ISO	<i>International Organization for Standardization</i>
LO	<i>Luenberger Observer</i>
MHE	<i>Moving Horizon Estimator</i>
MLP	<i>Multi-Layer Perceptron</i>
MLR	<i>Multivariate Least Squares</i>
MWPCA	<i>Moving Window Principal Component Analysis</i>
NBR	Norma Brasileira
NFS	<i>Neuro-Fuzzy System</i>
NLPLS	<i>Non-Linear Partial Least Squares</i>
NMSE	<i>Normalized Mean Square Error</i>
NNPLS	<i>Neural-Network based Partial Least Squares</i>
NRMSE	<i>Normalized Root Mean Square Error</i>
OPC	<i>Optical Particle Counter</i>
PCA	<i>Principal Component Analysis</i>
PCR	<i>Principal Component Regression</i>
PLS	<i>Partial Least Squares ou Projection to Latent Structures</i>
RBFN	<i>Radial Basis Function Network</i>
RLS	<i>Recursive Least Squares</i>
RNA	Rede Neural Artificial
RNN	<i>Recurrent Neural Network</i>
RPCA	<i>Recursive Principal Component Analysis</i>
SMO	<i>Sliding Mode Observer</i>
SOM	<i>Self-Organizing Neural Model</i>
SR	<i>Stepwise Regression</i>
SVM	<i>Support Vector Machines</i>
TS	<i>Takagi-Sugeno</i>

SUMÁRIO

1 INTRODUÇÃO	13
1.1 DEFINIÇÃO DO PROBLEMA.....	16
1.2 DELIMITAÇÃO DO TEMA.....	16
1.3 TEMA DE ESTUDO	16
1.4 OBJETIVOS	16
1.4.1 Objetivo Geral	16
1.4.2 Objetivos Específicos	17
1.5 JUSTIFICATIVA	17
1.6 ESTRUTURA DO TRABALHO.....	19
1.7 PRODUÇÃO TÉCNICO-CIENTÍFICA.....	19
2 FUNDAMENTAÇÃO TEÓRICA	21
2.1 DESENVOLVIMENTO DE SENSORES POR <i>SOFTWARE</i>	21
2.1.1 Metodologia de desenvolvimento	22
2.1.2 Escolha das variáveis secundárias	25
2.1.3 Escolha da classe e estrutura do modelo	28
2.1.4 Escolha da técnica de estimação do modelo	29
2.1.5 Técnicas de correção de modelos	32
2.2 SALAS LIMPAS E SISTEMAS HVAC	37
2.2.1 Norma brasileira para salas limpas e ambientes controlados	38
2.2.2 Característica das partículas em salas limpas	39
2.2.3 Característica de sistemas HVAC em salas limpas	41
2.2.4 Geração e remoção de partículas em salas limpas	44
2.2.5 Métodos de medição de concentração de partículas	46
3 REVISÃO BIBLIOGRÁFICA	49
3.1 SENSORES POR <i>SOFTWARE</i> : HISTÓRICO E APLICAÇÕES	49
3.2 MODELAGEM DE SENSORES POR <i>SOFTWARE</i>	52
3.2.1 Trabalhos desenvolvidos utilizando modelos fenomenológicos	53
3.2.2 Trabalhos desenvolvidos utilizando modelos empíricos	53
3.3 MANUTENÇÃO DE SENSORES POR <i>SOFTWARE</i>	55
3.4 MONITORAMENTO DE CONCENTRAÇÃO DE PARTÍCULAS	58
3.5 EFICIÊNCIA ENERGÉTICA EM SALAS LIMPAS	59

3.6 CONSIDERAÇÕES FINAIS	63
4 METODOLOGIA E RESULTADOS PRELIMINARES.....	66
4.1 MODELAGEM DO SENSOR POR <i>SOFTWARE</i>	66
4.1.1 Modelo de estimação de concentração de partículas.....	66
4.1.2 Estudo de caso do modelo para determinação de seus parâmetros.....	72
4.1.3 Simulações realizadas com o modelo	78
4.1.4 Validação do modelo de estimação de concentração de partículas.....	82
4.2 CORREÇÃO DO SENSOR POR <i>SOFTWARE</i>	86
4.2.1 Estrutura final do sensor por <i>software</i>	92
4.3 SENSOR POR <i>SOFTWARE</i> COM FILTRO DE KALMAN.....	93
4.3.1 Representação do modelo em espaço de estados.....	95
4.3.2 Implementação do filtro de Kalman em MATLAB	96
5 RESULTADOS GERAIS.....	100
5.1 REDUÇÃO DA TAXA DE TROCAS POR HORA	103
5.2 REDUÇÃO DO PERCENTUAL DE RENOVAÇÃO DE AR	104
5.3 EFICIÊNCIA DOS FILTROS	104
5.4 DEMAIS PARÂMETROS DO MODELO.....	105
6 CONSIDERAÇÕES FINAIS	108
6.1 CONTRIBUIÇÕES PARA TRABALHOS FUTUROS.....	109
REFERÊNCIAS	111

1 INTRODUÇÃO

Os sensores por *software* são uma ferramenta de grande valor em diversas aplicações industriais, incluindo refinarias, indústrias química e alimentícia, sistemas elétricos de potência, usinas nucleares, monitoramento de poluição urbano e industrial, apenas para citar alguns exemplos. Eles são usados para resolver diferentes problemas, como estimativas de variáveis de interesse do processo, sistemas de medição redundantes, predição em tempo real para controle de plantas, validação de sensores e estratégias de diagnósticos de falhas (FORTUNA, 2007).

Segundo Lotufo (2010), na indústria de processos a qualidade do produto é tipicamente monitorada através de análises em laboratório ou através de analisadores em linha. Essas análises apresentam um tempo morto relativamente grande quando comparados à dinâmica do processo. Geralmente existem no processo variáveis secundárias que estão sendo monitoradas em tempo real, como temperatura, pressão, vazão etc.

O desafio consiste em estimar uma variável de interesse do processo que auxilie no seu controle de qualidade. Algumas das razões que motivam a estimação dessa variável podem ser citadas como a impossibilidade física de medição dessa grandeza ou o sensor possuir um custo elevado ou ainda que o sensor não esteja disponível momentaneamente no mercado (FORTUNA, 2007).

Conforme Gonzales (1999), essa variável precisa estar relacionada com as variáveis secundárias do processo. Em sistemas caixa-preta, onde o engenheiro de controle não possui acesso ao modelo do sistema, podem ser utilizadas técnicas para estimar a melhor relação entre as variáveis secundárias que determinam o valor da variável de interesse. Portanto, ao acompanhar a variável de interesse em tempo real, o tempo de resposta na atuação do operador ou do sistema de controle da planta sobre as variáveis manipuladas do processo diminui consideravelmente, com isso obtendo-se um produto de melhor qualidade.

De acordo com Lotufo e Garcia (2008), esse conjunto de técnicas utilizadas para estimar uma variável de interesse do processo utilizando variáveis secundárias pode ser encontrado na literatura com diversas denominações além de sensores por *software*: sensor virtual, analisador virtual, modelo de inferência e mais frequentemente como *softsensor*, por ser a junção das palavras “sensor” e “*software*”, pois resumidamente, trata-se de um algoritmo de estimação (*software*) que prevê

estimativas *online* de variáveis não medidas a partir de dados coletados na planta por sensores. Devido a serem os mais frequentes na literatura, os termos “sensor por *software*” e “*softsensor*” serão utilizados no restante desta dissertação.

A implementação de um sensor por *software* pode ser simples para sistemas lineares e para os que apresentam uma baixa não-linearidade, mas pode ser um pouco mais complexo para sistemas com fortes não-linearidades. Porém, os sensores por *software* sempre apresentam a importante característica de custarem uma pequena fração do sensor físico da grandeza de interesse instalado no sistema, desde que exista previamente uma instrumentação e aquisição de dados já instalados (DIEHL, 2009).

Segundo Miranda (2003), a modelagem de um *softsensor* pode ter três abordagens: fenomenológica ou caixa branca, baseada nos fenômenos naturais do processo; empírica ou caixa preta, em que se utilizam técnicas de regressão multivariável para relacionar as variáveis de entrada e saída do modelo; e por último, semiempírica ou caixa cinza, que possui características das duas primeiras abordagens citadas.

Fortuna *et al.* (2007) apontam que os modelos semiempíricos são os mais indicados para o desenvolvimento de um *softsensor* para processos em que um pequeno histórico de dados está disponível e que possuem comportamentos físico-químicos demasiadamente complexos e dispendiosos para serem equacionados.

Considerando a abordagem de modelagem supracitada, geralmente inicia-se a partir de uma abordagem fenomenológica que gera uma estrutura de equações e obtém-se os seus coeficientes a partir dos dados existentes dos sensores do processo, por técnicas de aproximação, como mínimos quadrados recursivo, por exemplo (MUSTAFARAJ *et al.*, 2010).

Os sistemas HVAC são utilizados nas salas limpas, presentes nas indústrias de semicondutores, farmacêutica e na área médica, controlando temperatura, umidade e pressão, além de efetuar a inserção (insuflamento) de ar ultra limpo, que passa por diversas etapas de filtragem das impurezas que afetam a qualidade do produto ou processo. Porém, na maioria dos casos, sem efetuar um monitoramento *online* da concentração de partículas dispersas no interior da sala limpa, e conseqüentemente, sem utilizar essa variável como auxiliar do sistema de controle do sistema HVAC.

Na indústria de semicondutores, Adachi *et al.* (1991) comprovaram que a deposição de partículas presentes no ar sobre o material semicondutor pode causar um mau funcionamento dos circuitos ou um decréscimo no rendimento. Levy (2015), Matthew *et al.* (2010), Noh *et al.* (2010) e Zhao e Wu (2005), analisaram a relevância de se monitorar a quantidade de partículas em relação à vazão de ar (ventilação) imposta na sala limpa pelo sistema de ventilação (insuflamento) do HVAC. Além de verificarem que em muitas salas limpas a vazão de ar é fixada em valores acima do necessário, *i.e.*, energia desperdiçada pelo insuflador, que mantém o ar ultra limpo sempre circulando na sala limpa, diminuindo a quantidade de partículas em suspensão no ar por diluição.

Além disso, existem faixas de valores relativas à quantidade e tamanho de partículas aceitáveis em uma sala limpa, que são definidas em 9 classes de limpeza do ar, de acordo com a norma brasileira vigente desde 2005, a NBR ISO 14644-1.

Considera-se relevante o estudo de Ahmad *et al.* (2016), que menciona que nas últimas duas décadas vêm se buscando o controle eficaz dos sistemas HVAC, pois estes representam o principal consumo de energia dos prédios residenciais, comerciais e industriais.

Portanto, torna-se interessante que o controle de um sistema HVAC considere a quantidade de partículas da sala limpa uma variável relevante, para que sua eficiência energética seja melhorada de acordo com a utilização da sala limpa, *i.e.*, considerando perturbações como máquinas e pessoas em movimento, que são fontes geradoras de contaminantes do ar limpo. Loomans *et al.* (2019) afirmam que reduzindo em 33% a velocidade de um insuflador de um sistema HVAC, consegue-se uma redução de 66% de sua energia consumida, em média.

O monitoramento *online* da concentração de partículas, através de uma estimativa dada pelo sensor por *software*, contribui na qualidade dos produtos que venham a ser fabricados dentro de uma sala limpa, garantindo a operação da sala conforme sua classe definida em norma, independente do cenário de utilização. A aplicação do *softsensor* desenvolvido pode se estender além do estudo de caso deste trabalho (itt Chip da UNISINOS), como salas limpas de indústrias, *e.g.* a HT Micron.

A variável estimada pelo sensor por *software* poderá ser incluída na malha de controle do sistema HVAC, permitindo assim uma diminuição de seu consumo de energia em alguns cenários de utilização da sala limpa, através da variação da

velocidade do insuflador, reduzindo-a quando possível e elevando-a quando necessário.

1.1 DEFINIÇÃO DO PROBLEMA

Tendo como base o estudo de caso da sala limpa do Instituto Tecnológico itt Chip da UNISINOS, a dissertação está focada na aplicação de tecnologias para o desenvolvimento de sensores por *software* para monitorar e estimar a concentração de partículas em salas limpas.

1.2 DELIMITAÇÃO DO TEMA

O trabalho se limita ao estudo e implementação de tecnologias para desenvolver e validar um sensor por *software* e sua aplicação nas salas limpas do Instituto itt Chip.

1.3 TEMA DE ESTUDO

Considerando a delimitação acima, pretende-se responder às seguintes perguntas:

Qual(is) a(s) técnica(s) de desenvolvimento de sensores por *software* mais adequada(s) para a estimação da quantidade de partículas nas diferentes faixas de operação de um sistema HVAC? Qual o impacto em seu sistema de controle e em seu consumo de energia? Qual o impacto na qualidade do ar na sala limpa?

1.4 OBJETIVOS

Com base no contexto anteriormente apresentado, este trabalho tem os seguintes objetivos definidos.

1.4.1 Objetivo Geral

Desenvolvimento de um sensor por *software* para o monitoramento de partículas em salas limpas, tendo como caso de estudo as salas limpas do Instituto Tecnológico itt Chip da UNISINOS.

1.4.2 Objetivos Específicos

Além de aprofundar os conhecimentos sobre sensores por *software* e monitoramento de partículas em sala limpa, este trabalho tem como objetivos específicos:

- a) Estudar o comportamento da concentração de partículas sob diferentes cenários, introduzindo perturbações (fontes de contaminação do ar), tendo como caso de estudo a sala limpa do itt Chip;
- b) Estudar modelos caixa branca e caixa cinza para estimar o comportamento dinâmico da concentração de partículas;
- c) Analisar a influência da incerteza dos parâmetros dos modelos, para definir suas faixas de valores e propor uma estratégia para compensá-las;
- d) Validar os resultados da estimação da concentração de partículas comparando-os com as medições de sensores em campo;
- e) Propor que os valores estimados de concentração de partículas na sala limpa sejam utilizados como uma variável do processo no sistema de controle do sistema HVAC, por meio da variação da velocidade de seu insuflador. Analisar as vantagens e desvantagens em relação à qualidade do ar na sala e ao consumo de energia;

1.5 JUSTIFICATIVA

Comprova-se na literatura, através de diversos trabalhos como por exemplo, Sivak (2009) e Muratori (2012), que os sistemas HVAC são responsáveis por uma parcela significativa do consumo de energia, entre 40% e 60%, de uma edificação. Além disso, consideram que esses sistemas de condicionamento de ar necessitam de melhorias em seu sistema de controle no sentido de otimizar o seu consumo de energia, porém, sem deixar de atender às necessidades de temperatura, umidade e pressão no interior das edificações.

Nas salas limpas, o sistema HVAC precisa dispor de diversas etapas de filtragem do ar, para que se seja possível a minimização da concentração de partículas suspensas no ar, com o objetivo de garantir um processo produtivo de qualidade.

Na indústria de semicondutores, o processo produtivo de circuitos integrados é altamente dependente de um ambiente descontaminado. A deposição de partículas

nos materiais semicondutores pode inviabilizar ou reduzir a eficiência de microprocessadores, memórias e demais circuitos integrados.

Diversos estudos podem ser encontrados na literatura, que abordam o monitoramento e/ou controle da quantidade e tamanho das partículas presentes em salas limpas na indústria microeletrônica. Entre eles, destacam-se Cobo *et al.* (2008) e Vutla *et al.* (2013), que apontam que os sensores de concentração (ou contadores) de partículas disponíveis no mercado necessitam de alto investimento, além de estudarem como as diferentes faixas de concentração de partículas relacionam-se com a qualidade dos produtos fabricados em sala limpas.

Segundo Pereira (2008), a distribuição espacial da concentração de partículas na sala limpa não é simples de ser obtida, pois possui uma dinâmica não linear e seus valores são afetados por diversos fatores, como a quantidade e a distribuição de: pessoas e máquinas na sala, bem como se elas estão paradas ou em movimento; fluxo de ar proporcionado pelo sistema HVAC; abertura e fechamento das portas, etc.

Assim sendo, pode-se afirmar que a quantidade de partículas é uma variável importante de ser monitorada pelo sistema de controle HVAC, além das usuais (temperatura, umidade e pressão) para que se possa melhorar seu gerenciamento de consumo de energia de acordo com a utilização da sala limpa.

Considerando que foram encontrados poucos artigos publicados até a entrega desta dissertação, relacionados ao desenvolvimento de modelos matemáticos para estimação de concentração de partículas em suspensão na sala limpa, como Xu (2003), Sun (2010) e Zhou (2017), mas nenhum deles apresentando uma proposta de inclusão da variável estimada no sistema de controle do HVAC, este trabalho passa a ter grande contribuição acadêmica. Soma-se a isso o fato de o modelo matemático utilizado pelo sensor por *software* desenvolvido ter um número maior de parâmetros que os citados acima, pois foram acrescentadas variáveis que aumentam a precisão da predição do modelo, tornando-o uma ferramenta de extrema importância para auxiliar na manutenção da qualidade do processo produtivo, possibilitando ao operador da planta verificar em tempo real se a quantidade de partículas por metro cúbico está condizente com a classe da sala limpa definida pela norma NBR ISO 14644-1.

1.6 ESTRUTURA DO TRABALHO

Este trabalho apresenta um estudo dirigido à metodologia necessária para desenvolvimento de sensores por *software*, abordando técnicas que possibilitem implementá-los no monitoramento de concentração de partículas em salas limpas.

Para uma melhor compreensão do trabalho, este será dividido em cinco capítulos, estruturado na seguinte ordem:

Capítulo 1 – Introdução: Este capítulo apresenta a definição do tema, o alcance do projeto, os objetivos gerais e específicos e a justificativa destacando a motivação e importância desta pesquisa.

Capítulo 2 – Fundamentação teórica: Este capítulo apresenta uma síntese da fundamentação teórica das principais técnicas utilizadas no desenvolvimento de *softsensors*. Além de fundamentos básicos sobre salas limpas, concentração de partículas e sistemas HVAC.

Capítulo 3 – Revisão bibliográfica: Este capítulo apresenta uma revisão bibliográfica do histórico, aplicações e estado da arte em relação à sensores por *software* na indústria e monitoramento de concentração de partículas em salas limpas.

Capítulo 4 – Metodologia: Este capítulo apresenta uma síntese das ferramentas, métodos e procedimentos utilizados no trabalho.

Capítulo 5 – Resultados: Este capítulo apresenta a aplicação das técnicas estudadas em torno da metodologia proposta e os resultados obtidos no estudo de caso.

Capítulo 6 – Considerações finais: Este capítulo apresenta as principais conclusões e considerações do projeto, bem como sugestões para a sua continuidade em trabalhos futuros.

1.7 PRODUÇÃO TÉCNICO-CIENTÍFICA

Relatórios de pesquisa:

- **FLORES, E. O.** Modelos de predição de concentração de partículas em suspensão no ar em salas limpas: Simulações e análises dos modelos mais citados na literatura.

- **FLORES, E. O.** Desenvolvimento de um sensor por *software* utilizando Filtro de Kalman para predição de concentração de partículas em suspensão no ar em salas limpas.

Artigos submetidos em congressos:

- 1) Congresso Brasileiro de Automática (CBA) 2020:
 - **FLORES, E. O., MEJIA, R. I. G., PORCIÚNCULA, C. B.** Melhoria na eficiência energética da ventilação de salas limpas obtida por modelo de estimação de concentração de partículas.
- 2) Congresso Brasileiro de Engenharia Química (COBEQ) 2020:
 - **FLORES, E. O., MEJIA, R. I. G., PORCIÚNCULA, C. B.** Desenvolvimento de um sensor por *software* para estimação da concentração de partículas em salas limpas.

2 FUNDAMENTAÇÃO TEÓRICA

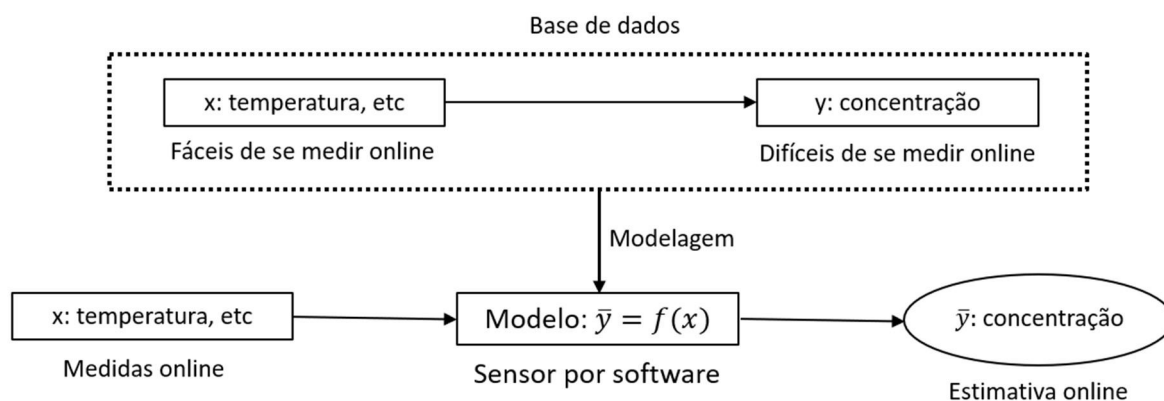
Nesta seção será descrita a fundamentação teórica necessária para a implementação das técnicas que serão utilizadas na metodologia para cumprir os objetivos específicos propostos.

2.1 DESENVOLVIMENTO DE SENSORES POR SOFTWARE

Na operação de plantas industriais, torna-se necessário monitorar as condições de operação e controlar as variáveis do processo. Assim, variáveis de processo como temperatura, pressão, nível de líquido e concentração de produtos precisam ser medidas em tempo real. No entanto, algumas variáveis do processo não são fáceis de serem mensuradas em tempo real devido às dificuldades técnicas, grandes atrasos de medição, alto custo de investimento e dificuldade de instalação de um sensor físico, entre outros.

Dessa forma, sensores por *software* são amplamente utilizados para estimar valores de variáveis de processo que são difíceis de medir tempo real. A Figura 1 ilustra seu conceito básico. Um modelo inferencial é construído por variáveis de processo que são fáceis de medir em tempo real, chamadas de variáveis x , e variáveis de processo difíceis de medir em tempo real, chamadas de variáveis y . Os valores de y podem então ser estimados usando esse modelo com muita precisão (ENGEL e GASTEIGER, 2018).

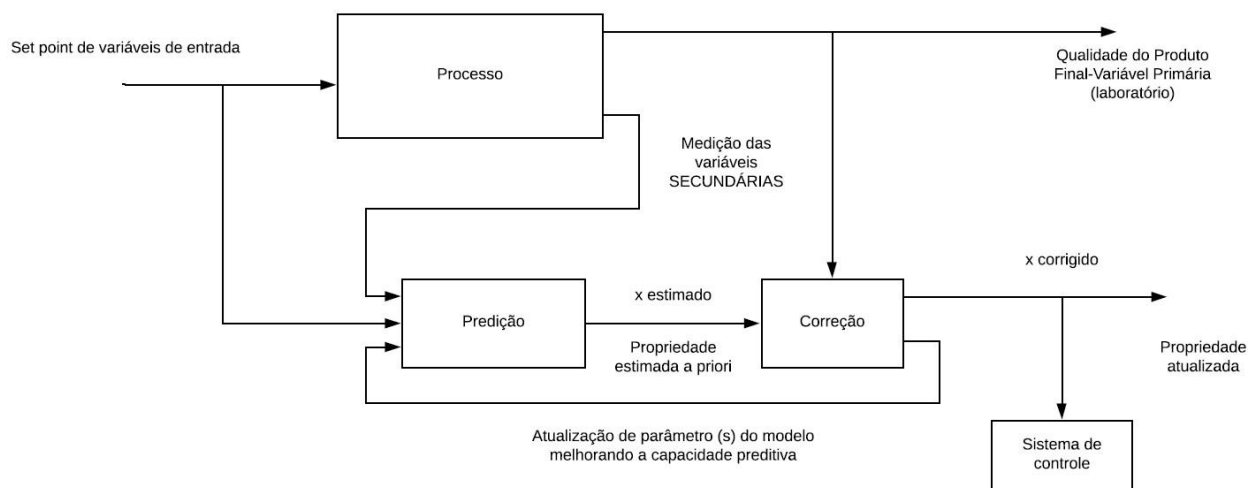
Figura 1 - Conceito básico de um sensor por *software*



Fonte: Adaptado de Engel e Gasteiger (2018).

De acordo com Fortuna *et al.* (2007), os *softsensors* estimam valores de variáveis difíceis de medir continuamente e, em seguida, os valores estimados podem ser usados, após passar por uma etapa opcional de correção, no controle contínuo do processo, conforme pode ser observado na Figura 2.

Figura 2 – Sensor por *software* inserido na malha de controle do processo



Fonte: Adaptado de Facchin (2005).

Segundo Kadlec e Gabrys (2009), a maioria das aplicações industriais são complexas de serem modeladas apenas partir dos fenômenos físico-químicos envolvidos, por isso empregam *softsensors* como um modelo de regressão linear construído utilizando variáveis secundárias do processo, fáceis de se obter, para prever uma determinada variável de interesse, que muitas vezes se refere à qualidade do produto. Na literatura essa abordagem é denominada estimativa ou predição baseada em dados (do inglês *data-driven*).

Sun (2010) afirma que para processos menos complexos e que dispõem de poucos sensores físicos espalhados pela planta, a abordagem fenomenológica torna-se a mais indicada. Trata-se de uma abordagem analítica, os chamados modelos mecanicistas, derivados dos princípios básicos e fundamentais.

2.1.1 Metodologia de desenvolvimento

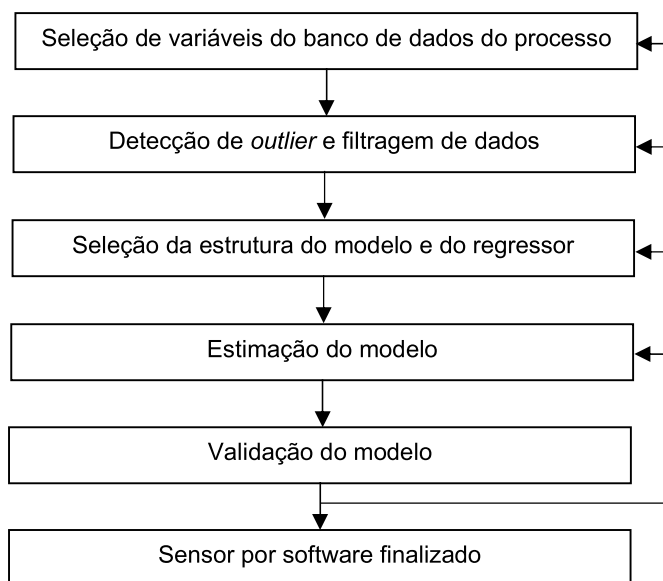
As possibilidades de modelagem de sensores por *software* dividem-se em três classes de modelos:

- Modelos fenomenológicos ou caixa branca: Relacionam as variáveis secundárias e as primárias através de equações que descrevem o comportamento físico-químico do sistema, balanço de massa e energia, cinéticas de reação, *i.e.*, possuem um foco voltado aos fenômenos e usam leis e modelos teóricos para descrevê-los.
- Modelos empíricos ou caixa preta: São modelos sem qualquer base fenomenológica, utilizando tipicamente relações empíricas, técnicas de análise estatísticas mono ou multivariáveis e modelos de regressão para estabelecer uma relação entre dados de entrada e saída. Os dados são provenientes de sensores já instalados no processo, por isso também são denominados como baseados em dados. Alternativas são utilizadas, *e.g.*, Redes Neurais Artificiais, Sistemas Nebulosos (fuzzy) e Algoritmos Genéticos.
- Modelos semiempíricos ou caixa cinza: São modelos baseados em simplificações de modelos fenomenológicos, os quais durante o processo de simplificação acabam gerando parâmetros que precisam ser ajustados através de métodos estatísticos de regressão para estimação de alguns parâmetros.

O *design* do *softsensor* do tipo caixa preta segue o diagrama de blocos da Figura 3. Observa-se que a cada nova etapa pode ser necessário retornar às etapas anteriores para que possam ser feitas alterações nos dados coletados, nas variáveis secundárias, na estrutura e parâmetros do modelo, até que o *softsensor* seja validado, apresentando um erro máximo tolerado com sua aplicação.

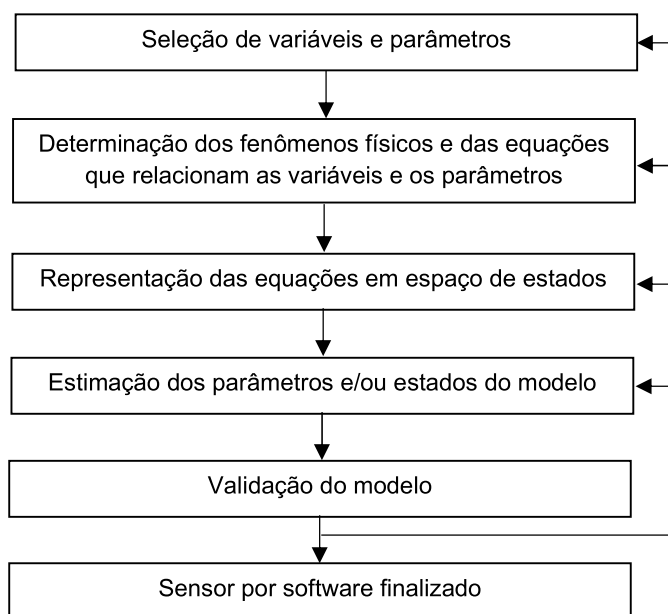
Na Figura 4 encontra-se o diagrama de blocos que representa as etapas de *design* de um sensor por *software* do tipo caixa branca. Nesse caso também ocorre com frequência um retorno às etapas iniciais para melhorar o modelo até que possa ocorrer a sua validação.

Figura 3 - Etapas de desenvolvimento de um sensor por *software* tipo caixa preta



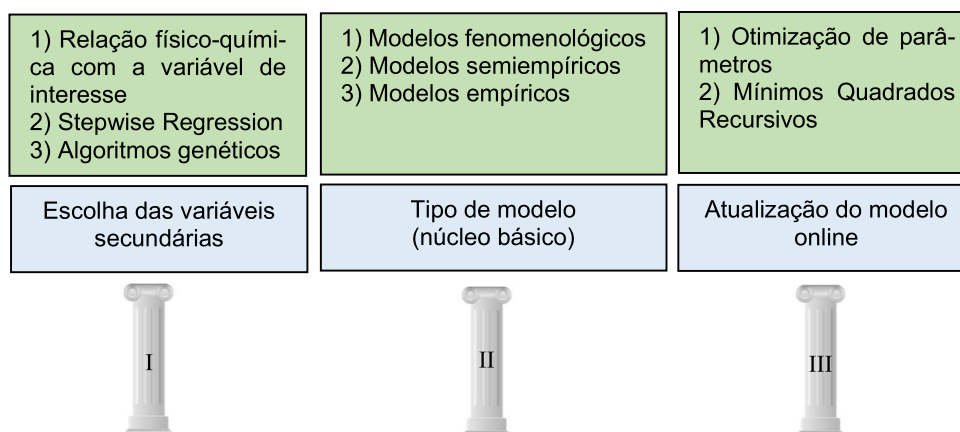
Fonte: Adaptado de Fortuna *et al.* (2007).

Figura 4 – Etapas de desenvolvimento de um sensor por *software* tipo caixa branca



Fonte: Adaptado de Solle *et al.* (2017).

Segundo Facchin (2005), existem três pilares básicos no desenvolvimento de um *softsensor*, conforme observa-se na Figura 5, que apresenta também alguns exemplos de métodos existentes e que podem ser empregados em cada uma das etapas.

Figura 5 – Os três pilares básicos de um sensor por *software*

Fonte: Adaptado de Facchin (2005).

2.1.2 Escolha das variáveis secundárias

O primeiro passo na construção de um modelo de um sensor por *software* consiste na seleção das variáveis que estarão presentes na sua composição. O banco de dados operacional da planta torna-se uma ferramenta muito útil de informação, que permite a identificação de parâmetros de interesse no processo. É interessante escolher dados que representem bem a dinâmica do sistema (WEBSTER, 1999).

O projetista do *softsensor* precisa ter um bom entendimento do processo, que possibilita a identificação de quais variáveis mais se relacionam com a variável que se deseja mensurar. Técnicas de análise de dados podem ser utilizadas na busca de padrões entre elas, como correlação linear e a análise dos componentes principais (PCA). A escolha dos dados passados, com atrasos regulares, também é considerada, inclusive o atraso pode ser considerado uma variável adicional do modelo (ZANATA, 2005).

Finalizada a etapa da escolha das variáveis, realiza-se a coleta de dados, que requer algum cuidado, pois dados ruidosos, incorretos ou indisponíveis podem propagar falhas durante todo o processo do sensor, alterando sua eficiência. Por isso, algumas técnicas são utilizadas para filtrar os dados coletados, eliminar *outliers* e diminuir o número de variáveis realmente relevantes. A mais simples é a Regra 3 sigma, em que são eliminados os dados que se afastam em mais de 3 vezes o desvio padrão da média da variável (FORTUNA *et al.*, 2007). A seguir encontra-se uma breve síntese de outras três técnicas também muito utilizadas para seleção de variáveis.

2.1.2.1 Análise dos Componentes Principais (PCA)

O objetivo desta técnica denominada PCA (*Principal Component Analysis*) é reduzir o conjunto de dados, que pode possuir dados compostos, correlacionados entre si ou não, ordenando por variabilidade decrescente. As variáveis transformadas são combinações lineares das originais e as menos correlacionadas podem ser removidas com uma perda mínima de informação (MA *et al.*, 2009).


Não obstante, em certos casos, a restrição de linearidade pode ser um limitante indesejável à adequada representação dos dados provenientes de sistemas não-lineares. Surge então o interesse por buscar projeções não-lineares. Nesse caso, a compressão se baseia na estrutura de correlação não-linear dos dados, denominada de NPCA (*non-linear Principal Component Analysis*).

2.1.2.2 Análise de Correlação Linear

Este método consiste em identificar quais variáveis possuem maior influência em outras, de acordo com o seu coeficiente de correlação. Ao plotar duas variáveis em um mesmo gráfico, chamado de correlação cruzada, é possível verificar o grau de relação existente entre elas, conforme pode ser observado na Figura 6, em que se verifica que existe uma correlação forte entre as duas variáveis, caso sejam ignorados os *outliers*.


A correlação de valores de uma única variável ordenados no tempo é chamada de autocorrelação, sendo um exemplo apresentado na Figura 7, onde a autocorrelação é nula, pois a média dos valores é zero. A análise gráfica de correlação torna-se viável para até três variáveis, gerando um gráfico 3-D. Para quatro ou mais variáveis a análise da correlação entre elas precisa ser feita calculando o coeficiente de correlação.

Figura 6 - Exemplo de correlação entre duas variáveis



Fonte: Elaborado pelo autor.

Figura 7 - Exemplo de correlação de uma variável



Fonte: Elaborado pelo autor.

Um estudo de correlação linear dos dados é necessário quando se quer identificar as variáveis que irão compor o modelo. Contudo, segundo Khalil (2002), este modelo somente será válido nas proximidades do ponto de operação escolhido, assim esse conjunto de variáveis úteis para compor o modelo só servirão para comportamentos próximos do ponto de operação, dependendo do grau de não-linearidade do sistema.

Conforme Aguirre (2004), as variáveis que apresentarem maior coeficiente de correlação com a variável de saída são preferenciais para serem escolhidas por apresentarem numericamente uma melhor relação com a saída.

2.1.2.3 Relação físico-química com a saída

Ao utilizar um modelo tipo caixa branca para representar um sensor por *software*, as variáveis são escolhidas com base nos fenômenos físico-químicos de cada uma delas com as entradas e saídas do modelo. Também chamado de mecanicista, pois pode ser construído pela visão da estrutura do sistema, dividindo-se o sistema em várias componentes e tentando entender o comportamento de todo o sistema através de cada parte e através das interações que ocorrem com as partes (SOLLE *et al.*, 2017).

Definem-se como variáveis do modelo as partes do sistema que se relacionam entre si, através de fenômenos físico-químicos, representados por equações. Geralmente esses fenômenos são variantes no tempo, tendo como consequência equações diferenciais que relacionam variáveis, parâmetros, entradas e saídas do modelo. Com base no conhecimento do processo, dos fenômenos e da influência destes sobre as componentes do modelo supracitadas, escolhem-se as variáveis e os parâmetros.

2.1.3 Escolha da classe e estrutura do modelo

Conforme citado no início da subseção 2.1.1, existem 3 classes de modelos: fenomenológicos (caixa branca), empíricos (caixa preta) e semiempíricos (caixa cinza).

Quando se estrutura um modelo com o método empírico, analisam-se os dados experimentais do processo, em que se faz algumas suposições, que podem ser simples ou complexas, na forma de um conjunto de equações, cuja resolução consiste na variável de interesse. Um modelo estruturado dessa forma possui a vantagem de ser facilmente implementado, quando as suposições feitas são simples. Porém, a exatidão da estimativa costuma ser baixa. Para uma alta exatidão e precisão, normalmente são necessários suposições complexas que resultam em conjuntos de equações maiores e mais complexas (SOLLE *et al.*, 2017).

Modelos do tipo caixa branca, estruturados através de equações oriundas dos fenômenos físico-químicos presentes no processo, costumam, na maioria dos casos apresentar alta exatidão e precisão na estimativa do valor de interesse. Em contrapartida, apresenta a desvantagem da dificuldade de implementação, em que quanto mais complexo o modelo, mais próximo do sistema real e mais preciso torna-se o modelo.

Ainda segundo Solle *et al.* (2017), não existe uma linha bem definida entre os métodos mecanicistas e empíricos e é comum encontrar na literatura modelagens em que se utilizam métodos de ambas as linhas de raciocínio.

Na prática, o usuário escolhe entre as duas estruturas de modelos, baseado na sua própria combinação do uso empírico e de sua intuição, fazendo progressos com ambas as estruturas, comparando-as e até combinando-as com o objetivo de obter o resultado com a margem de erro desejada.

Abaixo seguem as técnicas e métodos mais utilizados para estruturar modelos de sensores por *software*.

2.1.4 Escolha da técnica de estimação do modelo

Após escolhida uma das três abordagens supracitadas, torna-se necessário definir a estrutura do modelo e empregar uma das diversas técnicas existentes para estimar os parâmetros do modelo escolhido. A seguir são apresentados os conceitos básicos das técnicas mais utilizadas nas modelagens de sensores por *software* encontrados na literatura.

2.1.4.1 Stepwise Regression

Segundo Xu e Zhang (2001), este método trata-se da junção de outros dois, denominados *Forward Selection* e *Backward Elimination*. Ambos consistem em modelos construídos em etapas, sendo que no primeiro método, a cada etapa uma variável é introduzida e a adição de variáveis acaba quando não há mais melhora significativa do modelo; enquanto o segundo método consiste em: inicia-se com todas as variáveis e a cada etapa uma delas é removida. Para os dois métodos, cada etapa é testada através da correlação entre a variável inferida e o valor real.

No *Stepwise Regression (SWR)*, a cada adição de variável é realizada uma etapa de verificação para eliminação de variáveis redundantes. A avaliação de performance é feita em função do coeficiente de correlação parcial. Com base nessa avaliação, o método indica quais variáveis irão fazer parte do modelo do *softsensor*, bem como os parâmetros do modelo, que posteriormente precisa ser validado.

2.1.4.2 Regressão Linear Múltipla (MLR)

Segundo Aguirre (2004), o método mais simples pertencente à classe de modelos empíricos é a Regressão Linear Múltipla ou MLR (*Multivariate Least Regression*), que, justamente por ser uma regressão linear simples pelo método dos mínimos quadrados, apresenta eficiência apenas razoável e muitas limitações. Devido às suas características numéricas, frequentemente proporcionam soluções indefinidas, no momento da inversão de matrizes, devido ao mau condicionamento das matrizes de entrada de dados.

2.1.4.3 Regressão nos Componentes Principais (PCR)

Esta técnica surgiu para resolver parte dos problemas do MLR, como o mau condicionamento das matrizes de entrada de dados, que podem resultar em soluções indefinidas. A PCR (*Principal Component Regression*) é capaz de manipular com maior eficiência matrizes singulares ou quase-singulares, através da aplicação do PCA (*Principal Component Analysis*), eliminando a existência de dados correlacionados, por vezes reduzindo a dimensão do sistema para que ele deixe de ser indeterminado, concentrando assim apenas as informações importantes. A realização de PCA nos dados de entrada gera um novo conjunto de dados ortogonais, o que garante uma inversa estável.

2.1.4.4 Regressão por Mínimos Quadrados Parciais (PLS)

O algoritmo de regressão denominado PLS (*Partial Least Squares*) foi proposto por Wold *et al.* (1984), sendo também chamado Projeção em Estruturas Latentes (*Projection to Latent Structures - PLS*).

Enquanto o PCR utiliza PCA apenas nos dados de entrada, o PLS linear utiliza PCA nos dados de entrada e saída, de modo a maximizar a covariância entre eles. O modelo resultante desta técnica é simplesmente a relação existente entre as variáveis latentes.

Um dos aspectos fundamentais para a obtenção de um modelo é lidar com uma grande quantidade de variáveis medidas que são altamente correlacionadas. Modelos com excesso de parâmetros podem se ajustar bem ao conjunto de dados de treinamento, porém, podem levar a previsões ruins (KRESTA *et al.*, 1994).

Os métodos estatísticos de projeção multivariável, como o PLS, podem resolver este problema pela regressão a partir de um pequeno número de variáveis ortogonais, chamadas variáveis latentes. As variáveis latentes são uma combinação linear das variáveis originais. Como o objetivo dos modelos inferenciais é estimar valores futuros, ao invés de ajustar bem valores passados, os modelos obtidos pela técnica PLS podem atuar melhor que os métodos de regressão linear múltipla, *e.g.*, o MLR.

Conforme Engel e Gasteiger (2018), é uma técnica muito utilizada nos últimos anos, tanto o PLS original em sistemas lineares, como suas dezenas de variações que se mostram altamente eficiente também em sistemas não-lineares. Dentre essas variações convém citar modelos que mesclam PLS com Algoritmos Genéticos, Redes Neurais e Modelos Nebulosos (Fuzzy).

2.1.4.5 Redes Neurais Artificiais e Sistemas Nebulosos

No campo da inteligência artificial, Redes Neurais Artificiais (RNAs) são modelos paramétricos não-lineares que procuram realizar uma aproximação do mecanismo de processamento do cérebro humano (ATKINSON e HANDEWAK, 1998). São técnicas computacionais que apresentam um modelo inspirado na estrutura neural de organismos inteligentes e que adquirem conhecimento através da experiência ou aprendizado. Diferentemente das regressões lineares, as RNAs são capazes de incluir não linearidades (WERLE, 2012).

O processamento executado pelas RNAs utiliza muitos processadores simples (neurônios artificiais), altamente interconectados. A representação do conhecimento de uma rede neural está distribuída nas conexões e o aprendizado é feito diretamente do conjunto de dados, alterando-se os valores associados às conexões (LINHARES, 2007).

A lógica nebulosa foi um dos desenvolvimentos decorrentes da teoria dos conjuntos *fuzzy* (ZADEH, 1965) e foi primeiramente projetada para representar e trabalhar com o conhecimento que não pode ser expresso por medidas quantitativas.

A principal ideia dos algoritmos baseados em lógica *fuzzy* é imitar o raciocínio humano para controlar processos de difícil modelagem, grande transitoriedade ou forte não linearidade (PEREIRA e FRATINI. 1999).

Os sistemas de inferência nebulosa modelam os aspectos qualitativos do conhecimento humano através de regras linguísticas “se então” (ZADEH, 1965). É um ramo rigoroso da matemática, que dá origem aos números *fuzzy*, suas propriedades e operações (MUSSI *et al.*, 2009).

Segundo Yan *et al.* (2017), na última década verificou-se um crescimento significativo no número de artigos publicados envolvendo modelos de *softsensors* mistos, empregando lógica *fuzzy* e RNAs e todas as suas variações, como adaptativo *neurofuzzy*, ANN (*Analytical Neural Network*), MLP (*Multi-Layer Perceptron*), NNPLS (*Neural Network Partial Least Squares*), RNN (*Recurrent Neural Network*), TS (*Takagi-Sugeno model*), entre outros.

2.1.5 Técnicas de correção de modelos

Modelos de *softsensors* criados para predição do comportamento real de um determinado processo, por mais confiáveis que sejam, são suscetíveis a alterações no processo que ocorrem ao longo do tempo, podendo apresentar desvios no valor final de suas predições. Para evitar que os modelos se tornem obsoletos, é necessário que se apliquem técnicas para correção dos desvios e/ou adaptação dos modelos. Todas as técnicas fazem uso de valores de referência, tais como análise de laboratório que viabilizam as adaptações e correções (FORTUNA *et al.* 2007).

2.1.5.1 Correção de BIAS

Por tratar-se da técnica mais tradicional, também é a mais utilizada por ser a mais simplificada. Consiste na substituição do valor da predição, quando uma análise laboratorial for disponibilizada, pelo valor da predição acrescido da diferença (BIAS) entre o mesmo e a análise laboratorial.

Kadlec e Gabrys (2009) ressaltam que na maioria dos processos industriais, as análises laboratoriais podem levar horas para serem concluídas. Dessa forma, nos períodos situados entre essas análises, o *softsensor* pode ficar suscetível a erros, caso os parâmetros da planta sejam dinâmicos. Quanto mais elevada for essa dinâmica, torna-se altamente recomendável a correção online do modelo do *softsensor*, empregando os métodos apresentados nas próximas seções.

2.1.5.2 Otimização com restrições

Segundo Coello *et al.* (2006), a otimização é um ramo da matemática que se preocupa com a obtenção das condições que dão o valor extremo de uma função sob determinadas circunstâncias. Em outras palavras, ela pode ser definida como o processo de encontrar o valor máximo ou mínimo de uma função.

Um problema de otimização pode ser matematicamente definido por:

$$\text{Encontrar } \mathbf{x} \text{ que minimize } f(\mathbf{x}) \quad (1)$$

sujeito a

$$g_j(\mathbf{x}) \leq 0, \quad j = 1, 2, \dots, n_g \quad (2)$$

$$h_k(\mathbf{x}) = 0, \quad k = 1, 2, \dots, n_h \quad (3)$$

$$x_i^L \leq x_i \leq x_i^U, \quad i = 1, 2, \dots, n \quad (4)$$

Onde \mathbf{x} é o vetor das n variáveis de projeto, $f_i(\mathbf{x})$ é a função objetivo e $g_j(\mathbf{x})$ e $h_k(\mathbf{x})$ são as restrições de desigualdade e igualdade, respectivamente. Os limites das variáveis são determinados através da Equação 4, onde x_i^L é o limite inferior e x_i^U é o limite superior da variável x_i . Nas outras expressões, n , n_g e n_h são, respectivamente, o número de variáveis do projeto, número de restrições de desigualdade e igualdade.

2.1.5.3 Mínimos Quadrados Recursivos

O algoritmo de Mínimos Quadrados Recursivo (*RLS – Recursive Least Squares*), de acordo com Rowell (2008), gera o mesmo resultado que o Método dos Mínimos Quadrados ordinário, que encontra a curva que melhor se ajusta aos dados, minimizando uma função custo representada pela soma dos quadrados das

diferenças entre o valor estimado e os dados observados. Porém, no caso do MQR, cada novo ponto atualiza (recursivamente) os parâmetros de ajustes sem a necessidade de utilizar todos os pontos coletados, permitindo dessa forma, uma readaptação do modelo ao processo.

2.1.5.4 Observador de Luenberger

Conforme Gonzalez *et al.* (2016), além dos estimadores bayesianos, como o Filtro de Kalman, os algoritmos baseados em observadores, como o Observador de Luenberger (Luenberger Observer - LO) e o observador em modo deslizante (*Sliding Mode Observer - SMO*) são os mais utilizados.

Ao contrário dos estimadores bayesianos, o LO e o SMO consideram processos determinísticos (sem ruído). Os algoritmos LO e SMO são usados predominantemente em combinação com um modelo linear uma vez que a otimização pode ser comprovada sob tais condições. Porém, existem variações que podem ser utilizadas em modelos não-lineares, como o Observador Estendido de Luenberger.

A noção de otimalidade, no entanto, não se sustenta se o modelo não representa totalmente a física do sistema. Assim, LO e SMO são mais simples de implementar do que os estimadores bayesianos, mas sob condições de medição ruidosa, os algoritmos bayesianos têm um desempenho melhor. Portanto, a seguir serão abordados os principais estimadores bayesianos baseados no Filtro de Kalman.

2.1.5.5 Filtro de Kalman (KF)

Segundo Simon (2010), o Filtro de Kalman (*KF – Kalman Filter*) é o filtro linear ótimo. No caso do ruído gaussiano, ele fornece a máxima estimativa a posteriori com a menor covariância possível; enquanto com ruído não gaussiano, é ideal no sentido de apresentar o mínimo erro médio quadrático. É o mais amplamente estimador bayesiano utilizado, obtendo sucesso em diversas aplicações, apesar de ser limitado a apenas sistemas lineares.

Trata-se de uma ferramenta matemática, que estima os valores futuros de uma variável de interesse, baseada nas equações que descrevem um determinado sistema dinâmico real, utilizando os valores atuais e passados dos estados e das medições da variável de interesse.

Contudo, as equações sempre descrevem o sistema real de forma apenas aproximada, introduzindo um grau de incerteza nos valores inferidos; também existe incerteza na medição da variável de interesse, devido à qualidade da instrumentação e do ruído de medição. Tais incertezas podem ser descritas usando probabilidade.

Em síntese, o que o Filtro de Kalman faz é inferir os valores para os estados baseado no modelo do sistema e nas medições, considerando as distribuições de probabilidade de cada um (WELCH e BISHOP, 2004).

O algoritmo do Filtro de Kalman pode ser assim descrito simplificadamente:

- 1) Inicialmente uma predição dos estados é realizada baseada no modelo do sistema. Esta estimativa é chamada de *a priori*. A covariância desta predição é calculada utilizando as distribuições de probabilidade de cada estado;
- 2) Em seguida, é calculado o ganho de Kalman com base nas incertezas da predição e da medida da variável.
- 3) A estimativa da predição é corrigida da seguinte forma: Multiplica-se o ganho de Kalman pelo erro entre o valor atual da medição e o valor atual da estimativa. O resultado dessa operação é adicionado à estimativa *a priori*. Essa nova estimativa corrigida é chamada de *a posteriori*;
- 4) Por fim, é calculada uma medida das incertezas (covariâncias) dos estados após a correção.

Esse processo se repete a cada nova medição, produzindo estimativas estatisticamente ótimas sob o ponto de vista das distribuições de probabilidade dos estados das medições. As estimativas *a posteriori* serão usadas na predição das novas estimativas *a priori* da iteração seguinte. Esta natureza recursiva é um dos principais atrativos do Filtro de Kalman para implementações práticas.

2.1.5.6 Filtro de Kalman Estendido (EKF)

O Filtro de Kalman Estendido (*EKF – Extended Kalman Filter*) é a extensão mais amplamente usada do KF para sistemas não lineares. As formulações usam linearização local em um determinado ponto de interesse de operação do sistema não linear para estender o espaço do Filtro de Kalman, que é então aplicado neste ponto linearizado.

A linearização de um sistema com fortes não linearidades pode demandar alta carga computacional e propiciar resultados pouco eficientes. Em sistemas simples, podem ser obtidos jacobianos analíticos, mas isto raramente é possível na prática. Normalmente, os jacobianos numéricos precisam ser usados, mas são menos precisos, de alto custo computacional; e em alguns casos, podem não ser obtidos resultados devido a descontinuidades nos cálculos matriciais. Estas são as principais desvantagens na implementação do EKF (GONZALEZ *et al.*, 2016).

2.1.5.7 Filtro de Kalman Estendido com Restrições (CEKF)

Embora o Filtro de Kalman linear e o Estendido sejam ferramentas poderosas para estimativa de estado, existe a possibilidade de não ser possível a aplicação do valor estimado no sistema, devido ao valor estar fora de uma faixa de operação de um atuador, por exemplo. Pelo conhecimento do processo real, pode-se saber que os estados do sistema devem sempre satisfazer a certas restrições de igualdade ou desigualdade. Neste caso, modifica-se o filtro de Kalman para explorar este adicional de informações e obter um melhor desempenho.

A inclusão dessas restrições faz com que esse método seja de otimização e não recursivo. Portanto, o Filtro de Kalman Estendido com Restrições (*CEKF – Constrained Extended Kalman Filter*) é capaz de solucionar problemas com um menor custo computacional comparado ao EKF. Porém, está sujeito aos mesmos problemas de outras técnicas baseadas em otimização, como a possibilidade de a função objetivo possuir vários mínimos locais, o que pode elevar o esforço computacional se comparado a uma função objetivo com apenas um mínimo global (TONEL, 2008).

2.1.5.8 Estimador de Horizonte Móvel (MHE)

Em contraste com os algoritmos definidos acima, o MHE (*Moving Horizon Estimator*) leva em conta mais de uma única medição em cada etapa de estimativa. No entanto, nem todas as medições disponíveis são usadas, pois o custo computacional seria muito alto. Em vez disso, uma janela deslizante com M-passos para o passado que se move um passo à frente a cada passo k é usada. Isto implica que, quando uma nova medição está disponível, ela é incluída na janela de dados e a mais antiga é removida (BOEGLI *et al.*, 2013).

A estimativa consiste, então, em resolver um problema de otimização para calcular os estados ótimos e os parâmetros do sistema. Assim, a técnica de estimação resultante pode ser interpretada como a solução repetida de problemas de otimização de tamanho fixo que são gerados pela movimentação de uma janela de observação de tamanho fixo sobre uma medição crescente. Uma característica importante do MHE é que ele permite a estimativa de sistemas com restrições e não-linearidades severas. Este procedimento resulta em estimativas mais robustas para distúrbios externos do que outros métodos baseados no Filtro de Kalman (GONZALEZ *et al.*, 2016).

2.2 SALAS LIMPAS E SISTEMAS HVAC

Segundo Torreira (1991), salas limpas são ambientes controlados, que possuem um sistema de manutenção de qualidade do ar interior tendo como objetivo manter os níveis de contaminantes e particulados abaixo dos limites especificados por norma ou evitar a proliferação dos contaminantes.

As salas limpas nas últimas décadas estão sendo cada vez mais demandadas por diversos ramos da indústria, como farmacêuticos, cosméticos, alimentos, automóveis, comunicação, eletrônica e microeletrônica.

As indústrias de semicondutores são umas das mais exigentes, com relação a quantidade de partículas, exigindo um controle rígido dos níveis de possíveis contaminações, visto que na fabricação de circuitos miniaturizados, qualquer partícula mesmo as com diâmetro de nanômetros, pode danificar componentes, interferindo fundamentalmente no padrão de qualidade.

Problemas na produção podem ocorrer, causados por partículas ou gotas condensadas depositadas sobre os materiais semicondutores durante a fabricação ou encapsulamento de circuitos integrados. Nas demais indústrias, também existe a necessidade em vários níveis de controle de contaminação do ar interior, seja por poluentes tóxicos e perigosos, ou por partículas de poeira, mas que acabam por onerar os processos de fabricação de quaisquer tipos de produtos.

Nas salas limpas é possível quantificar e determinar o tamanho das partículas em suspensão, que são constantemente filtradas por um sistema de condicionamento de ar conhecido como HVAC (*Heating, Ventilation, and Air Conditioning*), que também

possui as funções de manter a temperatura e pressão estáveis e controlar o nível de umidade.

Os contaminantes são gerados por pessoas, processos e equipamentos e devem ser continuamente removidos do ar. O nível em que estas partículas precisam ser removidas depende dos padrões exigidos.

2.2.1 Norma brasileira para salas limpas e ambientes controlados

De acordo com Krippner (2018), no Brasil a norma vigente desde 2005 é a NBR ISO 14644 – Salas limpas e ambientes controlados associados, que é uma norma da ABNT equivalente à norma internacional ISO 14644, vigente desde 1999. A norma brasileira é dividida em 7 partes conforme a Tabela 1:

Tabela 1 - Norma NBR ISO 14644

ABNT NBR ISO	Título
14644-1	Classificação da limpeza do ar
14644-2	Especificações para ensaios e monitoramento para comprovar a contínua conformidade com a ABNT NBR ISO 14644-1
14644-3	Métodos de ensaio
14644-4	Projeto, construção e partida
14644-5	Operações
14644-6	Vocabulário (Cancelada pela ABNT em 2014)
14644-7	Dispositivos de separação (compartimentos de ar limpo, miniambientes)

Fonte: ABNT.

A norma NBR ISO 14644-1 classifica as salas limpas de acordo com o tamanho e o número máximo de partículas suspensas no ar, conforme a Tabela 2.

O anexo B da norma NBR ISO 14644-1 (2005) contempla os procedimentos necessários para a determinação da classificação de limpeza do ar para partículas em salas limpas, usando um instrumento denominado contador de partículas óptico. A contagem de partículas deve ser realizada em um número mínimo de pontos de medição, proporcional à raiz quadrada da área da sala limpa, de acordo com a Equação (5).

$$N_L = \sqrt{A} \quad (5)$$

Onde: N_L é o número mínimo de pontos de medição (arredondado para o número inteiro acima) e A é a área em m^2 da sala limpa.

Em cada ponto de medição, deve ser amostrado um volume de ar suficiente para que sejam contadas pelo menos 20 partículas, ou então pelo menos 2 L de ar, com um tempo de amostragem mínimo de 1 minuto.

Tabela 2 - Classificação de salas limpas de acordo com a NBR ISO 14644-1

Classe	Número máximo de partículas por m^3 de ar				
	$\geq 0,1 \mu m$	$\geq 0,3 \mu m$	$\geq 0,5 \mu m$	$\geq 1 \mu m$	$\geq 5 \mu m$
1	10				
2	100	10	4		
3	1.000	102	35	8	
4	10.000	1.020	352	83	
5	100.000	10.200	3.520	832	29
6	1.000.000	102.000	35.200	8.320	293
7			352.000	83.200	2.930
8			3.520.000	832.000	29.300
9			35.200.000	8.320.000	293.000

Fonte: ABNT.

2.2.2 Característica das partículas em salas limpas

A única maneira de controlar a contaminação é o controle total de todo o ambiente, monitorando e controlando taxas e direção de fluxo de ar, filtragem, pressurização, temperatura e umidade, além da entrada e saída de pessoas e material, da circulação de pessoas, dos equipamentos e materiais da linha de produção, entre outros.

Do ponto de vista das instalações, o controle de contaminação consiste na segregação tanto dos contaminantes exteriores, quanto dos produtos manipulados, a fim de evitar a contaminação dos outros produtos e do ambiente. Essa segregação é possível através de uma boa concepção e construção da distribuição interior, das utilidades e do equipamento de produção.

Um bom ajuste da distribuição interior permite circunscrever e proteger as áreas onde os produtos são manipulados. As utilidades e principalmente o sistema de climatização e filtragem do ar permite controlar a contaminação (SILVA, 2012).

Ashrae (2016) define contaminação como todo e qualquer material ou substância não desejada no ambiente. Em salas limpas, a contaminação é composta por sólidos aerotransportados e líquidos (aerossóis), descritos no Quadro 1.

Quadro 1 - Características de partículas

Estado físico	Condição	Origem e tamanho da partícula	Características dos materiais
Sólidos	Pó	Pela erosão do vento e dispersão de materiais pulverizados – partículas menores que 100 μm	Mineral: rochas, gesso, metais, argila. Vegetal: pólen, farinhas, fibras, outros. Animais: escamas da pele, pelo, lã, outros
	Fumaça	Por combustão incompleta de substâncias orgânicas – partículas entre 0,01 e 0,03 μm . Ou por sublimação e oxidação de metais fundidos – partículas entre 0,1 e 100 μm .	Tabaco, carvão, lenha, petróleo
Líquidos	Orvalho	Atomização de materiais líquidos sob pressão e temperatura.	Orvalho produzido por espirro
	Névoa	Condensação de vapores	Gotas formadas em virtude da condensação
	Vapores	Substâncias sólidas ou líquidas na sua fase gasosa	Substâncias em estado natural.
Gases	-	Não possuem formas, adaptando-se completa e uniformemente ao recipiente que os contém	-
Organismos aéreos vivos	Vírus	Podem variar entre 0,005 a 0,1 μm	Agrupam-se em colônias ou são aerotransportados por partículas
	Bactérias	Podem variar entre 0,4 a 12 μm	
	Esporos	Podem variar entre 10 a 30 μm	
	Pólen	Podem variar entre 10 a 100 μm	

Fonte: Torreira (1991).

Sun (2010) afirma que a quantidade de partículas em suspensão no ar de uma sala limpa é diretamente proporcional ao número de pessoas e ao nível de atividade desenvolvido por essas pessoas na sala limpa. Ao longo de um turno de trabalho em uma indústria de semicondutores, geralmente existe uma variação muito grande no número de pessoas presentes em uma sala limpa, bem como na atividade que exercem. A tabela 3 mostra a quantidade de partículas maiores que 0,1 μm que são geradas por indivíduo realizando diferentes tipos de atividades com um vestuário comum. Porém, dentro de uma sala limpa, com um vestuário adequado (macacão,

calçado e touca), a quantidade de partículas diminui consideravelmente, como apresentado na Tabela 4, onde também se considera uma taxa de geração de partículas por minuto.

Tabela 3 – Partículas geradas por indivíduo em função do tipo de atividade

Tipo de Atividade	Partículas geradas por minuto
Sentado ou em pé (sem movimento)	100.000
Sentado com pequenos movimentos	1.000.000
Levantando-se a partir da posição sentada	2.500.000
Caminhando a 1 m/s	5.000.000
Caminhando a 2 m/s	7.500.000
Caminhando a 5 m/s	10.000.000
Exercício de ginástica	20.000.000

Fonte: Torreira (1991).

Tabela 4 – Partículas geradas por indivíduo em função do vestuário

Tipo de Atividade	Vestuário comum	Vestuário de laboratório	Vestuário de sala limpa
Sentado e sem movimento	448.000	142.000	14.920
Sentado e movimento os braços	2.240.000	390.000	31.700
Caminhando a 1 m/s	4.450.000	462.000	48.600
Caminhando a 5 m/s	8.380.000	1.285.000	157.000

Fonte: Ramstorp (2000).


2.2.3 Característica de sistemas HVAC em salas limpas

A concentração de partículas em suspensão no ar é usada para determinar a classe de uma sala limpa. Técnicas como filtragem e disposição dos fluxos de ar limpo na sala promovidos pelo sistema HVAC são importantes no controle da concentração de partículas em suspensão no ar e na deposição de partículas sobre superfícies. Portanto, para contemplar essas características citadas, o sistema de climatização precisa ser projetado adequadamente levando em consideração as particularidades de cada sala limpa.

Existem duas formas de insuflar ou impulsionar o ar para dentro do ambiente, também chamados de regime de escoamento, conforme ilustrado na Figura 8 e descritos em detalhes abaixo:

- 1) Não Unidirecional ou turbulento: Dessa maneira o fluxo de ar nessa sala não mantém nenhuma regularidade, o controle de partículas nesse caso é feito por diluição. O fluxo de ar desordenado leva tempo para eliminar a contaminação, então há grande probabilidade de deposição das partículas nas superfícies dos produtos;
- 2) Unidirecional ou laminar: Ocorre um fluxo regular do ar, dessa forma a eliminação de partículas é feita por deslocamento. Esse fluxo laminar é possível graças ao *plenum* ou caixa de pressão, localizado antes do filtro permitindo uma distribuição homogênea.

Figura 8 – Fluxos de ar em salas limpas



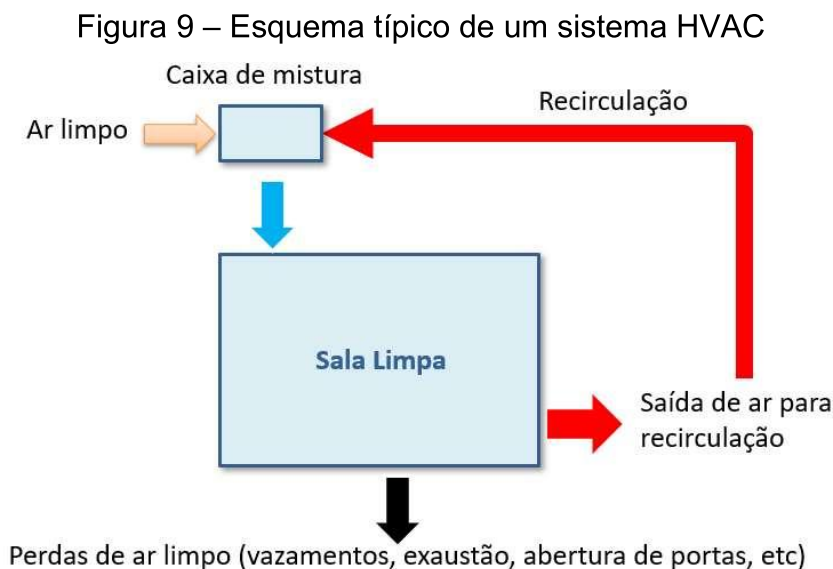
Fonte: Adaptado de Silva (2012).

De acordo com Ashrae (2016), podem se enumerar três tipos de sistemas HVAC:

- 1) Sistemas com renovação total de ar: Não há um reaproveitamento do ar, então não há contaminação cruzada. O ar é renovado constantemente. Porém, o sistema consome muita energia;
- 2) Sistemas com aproveitamento ou reciclagem do ar: Possibilita uma melhor eficiência energética, pois possibilita uma menor redução ou elevação da temperatura. A desvantagem é a necessidade de filtros em maior número e mais eficientes;
- 3) Sistemas com umidade controlada: Além da reciclagem do ar, há um desumidificador que possibilita o controle de umidade.

Nas indústrias de semicondutores, as salas limpas possuem um sistema HVAC do tipo 3, pois a umidade também precisa ser controlada, para que a umidade em excesso no ar não condense e gotículas possam se depositar sobre os materiais.

O esquema de um típico sistema HVAC utilizado em salas limpas pode ser observado na Figura 9.



Fonte: Adaptado de Ashrae (2016).

O fluxo de ar limpo e constante através da sala limpa consiste na maneira mais eficiente de remoção das partículas, sendo por diluição se o regime de escoamento for turbulento ou por deslocamento se o regime de escoamento for laminar (ASHRAE, 2016).

Esse fluxo de ar é introduzido na sala limpa pelo insuflador após o controle de sua temperatura e umidade na caixa de mistura, em que o ar passa por serpentinas onde circulam água quente e fria. O processo de limpeza do ar é realizado pelos filtros tipo HEPA (High Efficiency Particulate Air – 99,97% de eficiência) ou ULPA (Ultra Low Particulate Air – 99,999% de eficiência), sendo necessária uma maior cobertura de área de filtro para salas classificadas com maior classe de limpeza do ar.

A velocidade do insuflador e sua capacidade de vazão de ar determinará o número de trocas de ar de todo o volume da sala por hora, um importante parâmetro das salas limpas, do inglês ACH (*Air Changes per Hour*) ou ACR (*Air Change Rate*).

Na Tabela 5 encontra-se uma recomendação de alguns parâmetros típicos de sistemas HVAC para algumas classes de salas limpas.

Tabela 5 – Parâmetros típicos de sistemas HVAC em salas limpas

Classe ISO 14644-1	Trocas/h	Veloc. Ar (m/s)	Regime de escoamento	Cobertura de filtro	Tipo de filtro
1	> 600	>0,7	laminar	80-100%	ULPA
2	> 500	>0,6	laminar	70-100%	ULPA
3	> 400	>0,5	laminar	60-100%	ULPA
4	300-720	0,4-0,6	laminar/misto	40-70%	ULPA/HEPA
5	100-400	0,3-0,5	laminar/misto	30-60%	ULPA/HEPA
6	40-120	0,15-0,25	misto/turbulento	20-40%	HEPA
7	20-70	0,1-0,2	turbulento	10-30%	HEPA
8	5-40	0,05-0,1	turbulento	5-15%	HEPA
9	1-10	0,01-0,07	turbulento	2-10%	HEPA

Fonte: Ashrae (2016).

Segundo Ramstorp (2000), esses parâmetros auxiliam o projetista de salas limpas a dimensionar todos os dispositivos que compõem o sistema de condicionamento e limpeza do ar, como o diâmetro e potência do insuflador (*fancoil*) que é responsável por grande parte do consumo de energia elétrica de um sistema HVAC.

Outra característica necessária nas salas limpas é a sobrepressão. De acordo com Torreira (1991), recomenda-se que as áreas críticas devem ter diferencial de pressão positivo em relação à outra área adjacente menos limpa de 0,05 inH₂O (polegada coluna d'água) ou 12,5 Pa.

Quando não há sobrepressão, existe a possibilidade de infiltração de partículas por frestas. A abertura de portas exclui os diferenciais de pressão, com isso é necessário antecâmaras entre ambientes controlados.

2.2.4 Geração e remoção de partículas em salas limpas

Segundo Pereira (2008), a concentração de partículas no interior de uma sala limpa pode variar amplamente, sendo que os níveis de contaminação dependem das fontes geradoras de partículas e dos processos de remoção.

As fontes de contaminação podem ser externas ou internas. As partículas provenientes das fontes externas ou das áreas adjacentes podem ser impedidas por

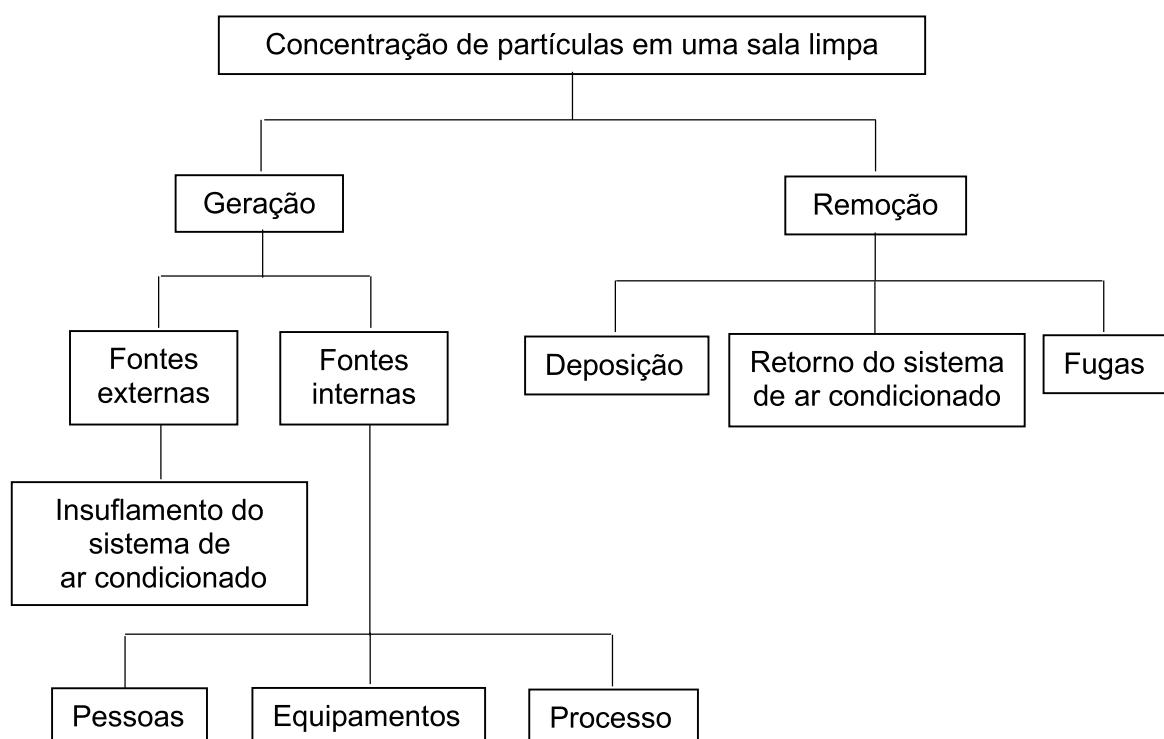
meio da sobrepressão, porém, dezenas de milhares de partículas conseguem adentrar a sala pelos filtros do sistema HVAC, pois nenhum filtro é capaz de bloquear 100% das partículas.

As fontes internas contribuem com a maior parcela da contaminação gerada no interior da sala. As pessoas representam uma fonte muito importante de partículas, cuja taxa de geração depende do número de pessoas presentes na sala, do grau de atividade (movimento) dessas pessoas e da eficiência da vestimenta no controle dessas partículas. O processo produtivo existente dentro da sala limpa, como os tipos e a quantidade de máquinas em operação também são fontes geradoras de partículas.

A remoção das partículas dispersas no ar do interior da sala ocorre pela ação do sistema de condicionamento de ar, pela deposição nas superfícies e pela fuga através das portas para as áreas adjacentes. O sistema HVAC remove as partículas através de três mecanismos: pelas trocas de ar, pela renovação e pelo processo de filtragem.

A Figura 10 resume em um diagrama os fatores que influenciam na concentração de partículas em suspensão no interior de uma sala limpa.

Figura 10 – Fatores que influenciam na concentração de partículas



Fonte: Pereira (2008).

A taxa de deposição descreve a quantidade de partículas que se depositam sobre as superfícies por unidade de tempo. Segundo He *et al.* (2005), a taxa de deposição tem sido investigada por meio de modelos teóricos e estudos experimentais, sendo que em salas limpas os estudos mostram que não há variabilidade significativa dos valores da taxa de deposição em função do tamanho das partículas.

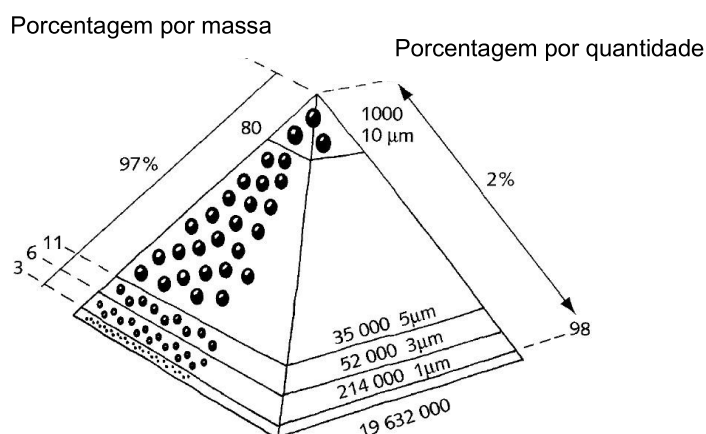
Alguns fatores que influenciam no valor da taxa de deposição em uma sala limpa são: área e volume da sala, velocidade e movimentação do ar, número de trocas de ar por hora. De acordo com Sun (2010), os efeitos da perda de partículas por deposição em um ambiente interno controlado, como uma sala limpa, podem em média ser aproximados como 8% da taxa de geração de partículas.

2.2.5 Métodos de medição de concentração de partículas

O espectro característico de partículas suspensas no ar pode ser representado por uma pirâmide, como a da Figura 11, que consiste em uma representação esquemática da distribuição do tamanho de partículas em uma amostra de ar hipotética, não proveniente de um ambiente controlado. Como regra, 99,9% do número total de partículas são menores do que 1 μm de diâmetro. De acordo com Ramstorp (2000), as partículas podem ser representadas em porcentagem em termos de seu peso e de sua quantidade.

A Figura 11 mostra uma situação em que um filtro é usado para remover partículas de um certo tamanho. O filtro tem capacidade de bloquear 97% das partículas em relação à massa total de todas as partículas. Isso corresponde ao filtro utilizado remover apenas 2% de todas as partículas quando se considera a quantidade total de partículas da amostra.

Figura 11 – Pirâmide das partículas: Relação inversa entre massa e quantidade




Fonte: Ramstorp (2000).

Em uma sala limpa, essa proporção entre massa e quantidade de partículas se altera, devido aos filtros existentes no sistema HVAC, que bloqueiam as partículas de grande tamanho e massa. Por esse motivo, em salas limpas, não é comum realizar-se a medição de partículas por meio de sua massa, mas sim através de contadores de partículas ópticos (OPC - *Optical Particle Counter*) que utilizam o princípio da reflexão de um raio de luz quando uma partícula o cruza.

Um contador de partículas óptico está representado na figura 12, em que o princípio de funcionamento pode ser explicado da seguinte maneira: o ar é sugado por uma bomba com vazão constante e cruza um raio de luz emitido por um diodo emissor de luz (LED), geralmente na faixa de 780 nm. Cada partícula gera reflexões no raio de luz que são detectadas por um fotodiodo. Este então transforma proporcionalmente as reflexões do raio luz em sinais elétricos, que são enviados a um condicionador de sinal e após para um microcontrolador que processa as informações. Por fim, um display exibe a quantidade de partículas que cruzam o feixe de luz, bem como seu tamanho, caso estejam dentro da faixa detectável para o qual o aparelho foi projetado. Geralmente a faixa de detecção situa-se entre 0,1 a 10 μm .

Como a vazão em que a bomba suga o ar é conhecida, o OPC também exibe a concentração de partículas, que consiste na quantidade de partículas por volume de ar. As unidades de volume geralmente utilizadas são: m^3 , cm^3 e ft^3 .

Figura 12 – Contador de partículas óptico



Fonte: Ramstorp (2000).

3 REVISÃO BIBLIOGRÁFICA

Neste capítulo será apresentada uma visão geral do histórico do desenvolvimento de sensores por *software*, além de trabalhos que abordam suas diversas aplicações para estimativas de propriedades em processos industriais. Por fim, uma revisão bibliográfica sobre sistemas HVAC e controle de partículas em salas limpas.

3.1 SENSORES POR SOFTWARE: HISTÓRICO E APLICAÇÕES

Segundo Kordon et al (2003), a ideia de se utilizar as medidas das variáveis disponíveis em determinado processo para deduzir parâmetros de qualidade deste processo foi primeiramente discutida academicamente no final dos anos 1960 e início dos anos 1970, em Rotach e Hadjinski (1966), Weber e Brosilow (1972) e Joseph e Brosilow (1978). Entretanto, os estimadores propostos requeriam modelos lineares e um conhecimento a priori dos distúrbios do sistema, sendo que ambas as suposições impunham significantes limitações. Portanto, suas propostas nunca foram postas em prática em uma aplicação real.

O termo denominado *softsensor* passou a ser empregado na literatura no artigo publicado por Morris (1989), denominado "*Softsensors in industrial process control*". Até então, eram utilizados os termos modelos de inferência, estimadores de parâmetros e sensores virtuais, como por exemplo, em Isermann (1984), Guilandoust et al. (1988) e Parrish e Brosilow (1988). Nos trabalhos dos autores supracitados, utilizavam-se modelos em espaço de estados dos sistemas, sendo que o emprego de medidas de variáveis secundárias era considerado apenas como ferramenta auxiliar, em partes do processo de estimação das variáveis de interesse.

A descrição de uma etapa intermediária de fusão e análise de dados que poderia ser convenientemente considerada como um substituto para um sensor hipotético abordou-se em um trabalho de Muir (1990), empregando o termo "sensor virtual", porém, sem apresentar uma aplicação prática para a metodologia desenvolvida.

Em Gonzales e Redard (1994), o autor utilizou apenas as medidas de variáveis secundárias do processo para estimação da variável de interesse, sem obter previamente o modelo da planta. A modelagem caixa-preta foi possível empregando

métodos matemáticos baseados em técnicas de regressão, que são capazes somente de modelar os dados e não de modelar o processo como um todo. No trabalho do referido autor, um dos pioneiros em aplicações na indústria do *softsensor*, o objetivo consistia em estimar a distribuição do tamanho de partículas em uma planta de moagem (trituração) em uma mina de cobre, localizada no Chile.

Segundo Leondes (2000), para o *softsensor* ser realizável, as variáveis secundárias não podem ter uma resposta mais lenta dentro do processo do que a variável de interesse a ser estimada. Em outras palavras, as variáveis secundárias necessitam possuir uma velocidade de reação igual ou mais rápida aos distúrbios não mensurados do sistema, quando comparadas à variável de interesse.

As aplicações em processos industriais dos *softsensors* são as mais diversas, sendo as mais citadas as implementações nas áreas automotiva, aeronáutica, química e biológica, monitoramento da qualidade do ar, tratamento de água e esgoto e indústria de papel.

Atkinson e Hanzevack (1997) descrevem um sistema de monitoramento de emissão de poluentes automotivo em tempo real empregando um *softsensor* baseado em rede neural. Um ambiente virtual para modelar um sistema de robô móvel múltiplo que inclui a capacidade para combinar sensores reais e virtuais é estudado por Dixon e Dolan (1999).

Um sensor por *software* para aceleração de aeronave, usada em um sistema de detecção e identificação de falha usando métodos de lógica nebulosa, é descrito em Oosterom (2000), em que o *soft sensor* pode ser aplicado dentro do sistema de monitoramento, no lugar de um dos sensores redundantes da aeronave, sendo que esta abordagem auxilia na identificação de sensores reais defeituosos.

A concentração de estudos relativos aos *softsensors* verificou-se estar nas áreas química e biológica, como nos processos produtivos das áreas química (em especial as refinarias) e alimentícia. Para exemplificar a última área citada, tem-se Siegel (2001), em que se estudou o micro-organismo *Listeria monocytogenes* que contamina alimentos processados. Um *softsensor* foi desenvolvido, baseado em um modelo que descreve o índice cinético de mortalidade térmica para o organismo em um tipo específico de carne processada e um modelo de transferência de calor numérico para pasteurização. No fim, o modelo retorna uma predição da quantidade de organismos residuais.

Nos processos em biotecnologia, um dos parâmetros mais importantes são as concentrações de biomassa. Gonzalez e Ascencio (2000) propõem a estimação inferencial, ou seja, o uso de *softsensors* para se obter uma estimação da biomassa a partir de conjuntos diversos de medições, por exemplo, temperatura, pH, taxa de evolução do oxigênio, taxa de evolução de dióxido de carbono e o tempo transcorrido na fermentação.

Na indústria de papel, *softsensors* são utilizados para determinar parâmetros de qualidade considerados críticos da folha de papel em tempo real, *i.e.*, durante a sua fabricação, como descrito em Merritt (2002). Antes dessa aplicação, tais medidas tinham que ser feitas *offline* ou depois do papel ser fabricado, quando uma amostra era levada para uma análise de laboratório, levando a descarte ou retrabalho de alguns lotes.

A mesma empresa que projetou e executou o sistema citado acima, *Pavilion Technologies*, produz também um sistema de monitoramento de efluente preditivo, ou seja, um *softsensor* para aplicação em plantas de tratamento de águas com o intuito de prever a demanda bioquímica de oxigênio para controle ambiental, com aplicações em tratamento de água em indústrias de papel, refinarias, processos químicos e estações de tratamentos de águas e resíduos urbanos (PAVILION, 2018).

Em Vancouver, EUA, situa-se outra empresa, a *dataPARC Solutions*, que comercializa um *software*, denominado *PARCmodel*, módulo integrante do *software PARCview*, o sistema supervisório desenvolvido pela empresa. Como está descrito no blog da empresa (dataPARC, 2018), o *PARCmodel* é capaz de realizar previsões de variáveis da qualidade do processo em tempo real, permitindo estimativas de propriedades que são impraticáveis ou impossíveis de se mensurar online. Esta aplicação cria modelos empíricos empregando técnicas como PCA e PLS e é capaz de efetuar a leitura dos sensores da planta advindos de qualquer fonte, como sistemas supervisórios, OPC, banco de dados e planilhas.

Existem muitas outras publicações que apresentam revisões e discussões acerca de aplicação de *softsensors* na indústria, entre elas: Gonzales (1999), focando nos modelos baseados em regressão linear; Fortuna (2007), que aborda técnicas de desenvolvimento e problemas encontrados nas implementações de *softsensors*, citando diversas aplicações na indústria baseadas em RNAs. Por fim, tem-se Kadlec e Gabrys (2009) e Janos *et al.* (2014), que apresentam uma completa discussão sobre todos os principais métodos de modelagem de *softsensors* utilizados na indústria.

3.2 MODELAGEM DE SENSORES POR SOFTWARE

Segundo Werle (2012), existem várias alternativas de modelos que podem ser utilizados por sensor por *software* aplicados em processos. Em geral, as técnicas mais utilizadas atualmente são as empíricas, mas podem ser empregados também modelos fenomenológicos. Apesar de apresentar vantagens, o modelo empírico ou inferencial requer um acompanhamento de suas estimativas, o que pode ser feito, por exemplo, através de análises de laboratório.

As categorias de modelagem podem ser divididas em três grupos: modelos fenomenológicos, chamados de caixa branca (*white-box*); modelos empíricos, chamados de caixa preta (*black-box*) e modelos semiempíricos, também conhecidos como caixa cinza (*gray-box*) (FORTUNA *et al.*, 2007).

Como descrito em Ventim (2010), os modelos fenomenológicos são os modelos com maior capacidade de extrapolação. Sua obtenção, no entanto, geralmente demanda um elevado esforço e conseqüentemente muito mais tempo para o seu desenvolvimento, especialmente em sistemas complexos.

Este modelo, sendo mais completo na sua descrição, é chamado de modelo rigoroso. Um modelo rigoroso pode ser preciso nos resultados, por outro lado, é extremamente complexo (CONZ, 2005).

Segundo Welch e Bishop (2004), normalmente os modelos rigorosos não são apropriados para aplicações em tempo real, pois em muitos casos o tempo de processamento para obtenção da informação de interesse não é aceitável ou pode comprometer a eficiência do sistema de controle. Estes motivos são os maiores obstáculos à aplicação destes métodos em ambientes industriais, principalmente em ambientes complexos.

Modelos empíricos, por sua vez, são caracterizados por não possuírem nenhuma base fenomenológica do sistema a ser modelado. Eles são baseados em métodos matemáticos, como técnicas de regressão, capazes de representar a relação entre as variáveis de entrada e saída de um processo. Sua capacidade de extrapolação é reduzida quando comparada a dos modelos fenomenológicos. A característica principal, quando se empregam modelos empíricos baseados em técnicas de regressão, é que eles não são capazes de modelar o processo inteiro, mas somente de modelar os dados do processo disponíveis naquele instante (CONZ, 2005).

3.2.1 Trabalhos desenvolvidos utilizando modelos fenomenológicos

Quintero-Marmol (1991) aplicou a técnica de estimativa de estado de sistemas denominada Observador Estendido de Luenberger para aplicação de perfis de composição instantâneos de colunas de destilação a partir de valores de temperatura. O observador de Luenberger é um método determinístico, ou seja, pressupõe que o modelo do processo é perfeito e que existe a ausência de ruídos e perturbações. Nesse trabalho supracitado, o autor relatou problemas de convergência quando se considerou a presença de ruídos nas medidas de temperatura.

Barolo e Berto (1998) também utilizaram um Observador Estendido de Luenberger e comprovaram que à medida que o número de variáveis aumenta e a correlação entre elas diminui, torna-se mais difícil sintonizar esse tipo de observador. Eles recomendam o uso de um estimador estocástico, como o Filtro de Kalman, para inferência.

Ito (2014) buscou desenvolver um *softsensor* com a acurácia e o poder extrapolativo dos modelos fenomenológicos sem comprometer a rapidez da execução e a confiabilidade exigidas pela aplicação, desenvolvendo um modelo fenomenológico simplificado, a partir do conhecimento e simplificação do processo de fracionamento em uma coluna de destilação multicomponente.


3.2.2 Trabalhos desenvolvidos utilizando modelos empíricos

Como mencionado no estudo de Junior (1996), Weber e Brosilow (1972) foram os primeiros a sugerir o uso de modelos de inferências empíricos com múltiplas variáveis para inferir uma determinada variável de interesse, enquanto possuíam o modelo em espaço de estados da planta, portanto um sistema caixa cinza. Nesse estudo, os resultados do modelo inferencial empregado na simulação de controle da planta mostraram-se satisfatórios. Além disso, os métodos propostos não foram aplicados em uma planta de um processo industrial real. Desde então, diversos trabalhos utilizaram esse tipo de raciocínio, *i.e.*, *softsensors* baseados em modelos de inferência empíricos, inclusive com aplicações em plantas industriais. Na literatura também são chamados de *data-driven softsensors* (sensores virtuais baseados em dados).

Muitos pesquisadores possuem estudos voltados à construção de modelos empíricos utilizando outra abordagem baseada em inteligência computacional, empregando Redes Neurais Artificiais (RNAs), como Fortuna *et al.* (2005), Linhares (2007), Kadlec e Gabrys (2009), Vijaya *et al.* (2011) e Werle (2012).

No entanto, segundo Janos *et al.* (2014), na literatura verifica-se que os métodos de construção dos modelos empíricos mais utilizados são derivados dos métodos estatísticos multivariáveis, sendo que os métodos PCA e PLS correspondem juntos a 38% do número de aplicações, conforme Figura 9.

Figura 13 - Métodos de construção de modelos de sensor por *software*



Fonte: Adaptado de Janos *et al.* (2014).

Os métodos presentes na figura acima são: *PCA* - *Principal Component Analysis*, *PLS* - *Partial Least Squares*, *MLP* - *Multi Layer Perceptron*, *RBFN* - *Radial Basis Function Networks*, *SOM* - *Self-Organizing Neural Models*, *SVM* - *Support Vector Machines*, *NFS* – *Neuro Fuzzy Systems*.

Um método estatístico multivariável foi abordado em Park e Han (2000), em que os autores propuseram uma maneira de lidar com a não-linearidade do processo, utilizando Mínimos Quadrados Parciais (PLS) como *softsensor* através de uma suavização multivariada com regressão ponderada local.

Outro método denominado Análise dos Componentes Principais (PCA) utilizou-se em Ma *et al.* (2009), que propuseram um *softsensor* baseado em dados, empregando o método citado para a escolha das variáveis chaves do processo que estariam presentes no modelo.

Em outro estudo, Zhiqiang e Zhihuan (2014), aplicaram um método denominado Análise dos Componentes Independentes (ICA), que cria um modelo de *softsensor* utilizando variáveis secundárias do processo que podem ser estatisticamente independentes entre si, ao contrário dos métodos baseados em PLS e PCR.

Em Venturim *et al.* (2018), estudou-se o desenvolvimento de um *softsensor* para monitoramento das propriedades de gases empregados em fornos de reaquecimento em indústrias siderúrgicas. Nesse estudo, utilizou-se e comparou-se quatro modelos de regressão, sendo dois deles baseados em mínimos quadrados parciais (PLS), um baseado em regressão de componentes principais (PCR) e outro por vetor de suporte (SVR).

Conforme Conz (2005), o emprego de RNAs possui a limitação de que a convergência se torna muito lenta quando muitos dados são utilizados para a sua representação, enquanto os modelos obtidos por regressão, como o PLS, apesar da enorme versatilidade, podem não representar de forma satisfatória o sistema quando este for altamente não-linear.

3.3 MANUTENÇÃO DE SENSORES POR SOFTWARE

Quando a implementação de um sensor por *software* é bem-sucedida, seu desempenho pode apresentar queda de rendimento quando as características do processo que se alteram ao longo do tempo. Por isso, os parâmetros dos *softsensors* precisam ser atualizados quando ocorrem essas alterações. Recomenda-se atualizar os parâmetros de um mesmo modelo de um *softsensor* ao invés de reconstruir modelos a cada intervalo de tempo (KANO e OGAWA, 2010).

Chen *et al.* (2015) propuseram um índice de incompatibilidade de modelo baseado em Filtro de Kalman para avaliar o desempenho preditivo de um determinado *softsensor* desenvolvido e coletar informações com o objetivo de se determinar o momento mais adequado para se atualizar o modelo. Quando o índice de compatibilidade atingir um certo patamar, o modelo pode ser atualizado através de uma regressão baseada em PLS.

Contribuições como a citada acima destacam-se por representar o estado da arte atualmente em *softsensors*, pois além de estimar com precisão uma certa variável de interesse de um processo, possuem uma ferramenta cuja função é avaliar em

tempo real o desempenho do estimador. Caso o erro de estimação da variável esteja acima de um valor pré-definido, o modelo ajusta-se automaticamente, modificando as variáveis de entrada, a estrutura ou os parâmetros do modelo.

O engenheiro que desenvolve um sensor virtual precisa preferencialmente conhecer o processo, seu comportamento, sua dinâmica e as variáveis correlacionadas com a variável de interesse. Quanto maior o nível de conhecimento do processo, mais facilmente será a escolha do(s) método(s) mais adequado(s) para a estimação desejada.

Nas tabelas 6 e 7 encontram-se um resumo com as principais aplicações de sensor por *software* em diversos ramos da indústria presentes na literatura.

Tabela 6 - Trabalhos com sensor por *software* que utilizam modelos fenomenológicos, além de empíricos baseados em Redes Neurais

Autor	Modelo	Método-Base	Aplicação e características
Quintero-Marmol (1991)	Fenomenológico	Observador Estendido de Luenberger	Composição em coluna de destilação. Bons resultados em processos sem ruídos e perturbações
Barolo e Berto (1998)	Fenomenológico	Observador Estendido de Luenberger	Indústria petroquímica. Sugestão de uso de Filtro de Kalman para melhorar os resultados
Ito (2014)	Fenomenológico	Filtro de Kalman	Composição em coluna de destilação. Simplificação do modelo completo da planta e predição de alguns parâmetros com KF
Sun <i>et al.</i> (2014)	Fenomenológico	SVR+EKF	Deslocamento do eixo do motor. Desempenho razoável, pois, o modelo utilizado não era não-linear e não representava fielmente o sistema
Fortuna <i>et al</i> (2005)	Empírico	RNA	Concentração de produtos em coluna debutanizadora. Estimação on-line de variáveis diminuiu o atraso que havia na obtenção das grandezas através de análise de laboratório
Linhares (2007)	Empírico	RNA	Composição de GLP. Resultados apenas satisfatórios. O autor sugere realimentar o modelo e corrigi-lo em tempo real
Vijaya (2011)	Empírico	RNR	Reação em coluna de destilação. Utilizou TDNN (Time Delayed Neural Network) para implementar o controlador e EKF para corrigi-lo em tempo real
Werle (2012)	Empírico	RNA	Composição em coluna de destilação. RNAs do tipo backpropagation e MLP (Multi-Layer Perceptron) foram utilizadas
Park e Han (2000)	Empírico	RNA	Controle de contenção de sílica na produção de aço. Utilizou-se RNA do tipo MLP e PLS

Fonte: Elaborado pelo autor.

Tabela 7 - Trabalhos com sensor por *software* que utilizam modelos empíricos baseados em métodos de regressão

Autor	Modelo	Método-Base	Aplicação e características
Ma <i>et al.</i> (2009)	Empírico	PCA	Monitoramento da pureza de o-xylene. Utilização do PCA para modelagem do softsensor.
Zhiqiang e Zhihuan (2014)	Empírico	ICA	Produção de polipropileno. Utilizando variáveis secundárias do processo que podem ser estatisticamente independentes entre si
Venturim (2018)	Empírico	PLS, PCR e SVR	Indústria siderúrgica. Estimação de propriedades de gases em fornos. Realizou-se uma comparação entre quatro métodos baseados em regressão multivariável
Dong <i>et al.</i> (1995)	Empírico	NLPLS e NLPCA	Monitoramento de gás NOx no exaustor de uma indústria. A análise de dados é feita com PCA, enquanto o modelo é gerado com NLPLS
Dunia <i>et al.</i> (1996)	Empírico	PCA	Identificação de falhas de sensores em sistemas de refrigeração e aquecimento. É proposto um índice que determina o status de cada sensor
Liu (2007)	Empírico	PCA+Fuzzy	Estimação do índice do fluxo de material na indústria de polietileno. PCA é combinado com Fuzzy. Apresentou melhores resultados que PLS
Sharmin <i>et al.</i> (2006)	Empírico	PLS	Estimação do índice do fluxo de material na polimerização em um reator autoclave
Dayal e McGregor (1997)	Empírico	PLS e RLS	Aplicação na indústria mineradora: Predição de diversas variáveis qualitativas. Modelo determinado com PLS e atualizado recursivamente através do RLS
Lee <i>et al.</i> (2006)	Empírico	NLPLS	Aplicação em processo de tratamento de esgoto. Estimação de variáveis de qualidade biológicas. NLPLS é integrado com modelos FIR e ARX
Li <i>et al.</i> (2000)	Empírico	RPCA	Aplicação na indústria de semicondutores, no processo de recozimento de metais. Softsensor adaptativo com PCA recursivo
Souza e Araujo (2014)	Empírico	RLS	Estimação de variáveis relativa à atividade de um catalisador da indústria de polímeros. Método mostrou-se melhor que OS-ELM
Tian e Deng (2010)	Empírico	IOLS	Aplicação em uma planta extrusora. Um sinal de correção ortogonal foi utilizado para minimizar os efeitos do ruído. Mostrou-se melhor que o PLS
Rotem <i>et al.</i> (2000)	Empírico	PCA	Aplicação em compressor de etileno.
Wang <i>et al.</i> (2005)	Empírico	MWPCA	Estimação de variáveis de processo em unidades de craqueamento catalítico. Utiliza um método derivado do PCA, com janelas de dados deslizantes
Amazouz e Pantea (2006)	Empírico	PCA e PLS	Aplicação na indústria de papel. Estimação de parâmetros pertinentes a secagem da madeira.

Fonte: Elaborado pelo autor.

3.4 MONITORAMENTO DE CONCENTRAÇÃO DE PARTÍCULAS

Na indústria de semicondutores e circuitos integrados, a deposição de partículas presentes no ar sobre o “*wafer*” semiconductor é um importante problema, pois essas partículas podem causar um mau funcionamento dos circuitos ou um decréscimo no rendimento (ADACHI *et al.*, 1991).

Por esse motivo, torna-se importante o monitoramento da quantidade de partículas em salas limpas, com o objetivo de minimizá-las para que a eficiência dos semicondutores seja a mais elevada possível. Segundo Cooper (1986), além dos cuidados que devem ser tomados nos acessos de pessoas e materiais para essas salas, outro modo de se controlar a quantidade de partículas presentes no ar das salas limpas é o sistema de ventilação, refrigeração e aquecimento, também chamado de HVAC, que efetua as trocas e filtragem do ar, controlando temperatura, umidade e pressão, fatores fundamentais não apenas na produção e encapsulamento de semicondutores, mas também em centros cirúrgicos, produtos farmacêuticos, entre outros.

Diversos estudos podem ser encontrados na literatura, que abordam o monitoramento e/ou controle da quantidade e tamanho das partículas presentes em salas limpas (ADACHI *et al.*, 1991; COBO *et al.*, 2008; NOH *et al.*, 2010; ZHAO e WU, 2005; VUTLA *et al.*, 2013).

Em Adachi *et al.* (1991), utilizou-se um instrumento óptico, denominado espectrômetro para mensurar a quantidade de partículas entre várias faixas de tamanho (0,12 a 7,5 μm).

Noh *et al.* (2010) e Zhao e Wu (2005) desenvolveram protótipos de espectrômetros e analisaram sua eficiência em relação à vazão de ar (ventilação) imposta na sala limpa pelo sistema de ventilação (HVAC).

Cobo *et al.* (2008) elabora uma revisão com as principais técnicas de monitoramento de partículas em salas limpas e os produtos comercialmente disponíveis no mercado, enfatizando que todos demandam um alto investimento para sua implementação, utilização e manutenção.

Vutla *et al.* (2013) estuda o impacto que as partículas presentes na sala limpa de uma indústria de semicondutores acarretam sobre a eficiência verificada nos produtos fabricados, sendo no estudo de caso, sistemas micro-eletromecânicos (MEMS), como giroscópios utilizados em celulares.

Chen *et al.* (2002) desenvolve um estudo numérico que aborda a influência da movimentação dos operadores no controle de partículas em uma sala limpa.

Lan *et al.* (2007) e Hu *et al.* (2014) propuseram um controle do fluxo de ar localizado em diversas partes da sala limpa, que foi dividida em miniambientes, sendo o controle do fluxo de ar baseado no monitoramento de partículas em cada miniambiente. Os autores obtiveram bons resultados com a instalação de FFUs (*Fan Filter Units*), que consistem em um insuflador com variação de velocidade, acoplado com um filtro HEPA, no teto de cada miniambiente da sala limpa, tornando possível um controle mais efetivo da concentração de partículas.

3.5 EFICIÊNCIA ENERGÉTICA EM SALAS LIMPAS

A revisão bibliográfica apresentada na seção anterior comprova a relação existente entre a quantidade de partículas e o sistema HVAC em uma sala limpa. Verifica-se ser inversamente proporcional a relação entre a ventilação e a quantidade de partículas que se depositam no produto de interesse na sala limpa.

A ventilação pode ser considerada também como a quantidade de trocas de todo o volume de ar existente em uma sala limpa em uma determinada quantidade de tempo. Essa capacidade de trocas de ar um sistema HVAC está diretamente relacionada com a energia consumida pelo sistema.

Considerando os estudos de Cobo *et al.* (2008) e Vutla *et al.* (2013), existem faixas de quantidade e tamanho de partículas aceitáveis para cada produto fabricado em uma sala limpa.

Portanto, torna-se interessante que o controle de um sistema HVAC considere a quantidade de partículas uma variável relevante, para aumentar a sua eficiência energética de acordo com a utilização da sala limpa.

Segundo Ahmad *et al.* (2016), o consumo de energia dos prédios (residenciais, comerciais e industriais) representam aproximadamente 40% de toda a energia consumida no planeta atualmente, bem como 30% do total de emissões de CO_2 . Nas últimas duas décadas busca-se uma maior eficiência energética dos prédios, sendo os sistemas de aquecimento, ventilação e ar condicionado, conhecidos por HVAC, um dos principais alvos, em que se torna importante o seu controle eficaz e inteligente com o objetivo de minimizar sua energia consumida.

Diversos trabalhos podem ser encontrados recentemente na literatura, como Mathew (2010) e Levy (2015), que abordam o padrão de consumo de energia de salas limpas, mostraram que o componente que mais impacta no custo operacional de salas limpas é a vazão de ar. Isso se deve ao fato da enorme quantidade de energia demandada por um ventilador de grande porte, chamado de insuflador, para manter o ar sempre circulando, renovando o ar ultra limpo dentro da sala limpa. Apenas um pequeno número de artigos pode ser encontrado na literatura que abordam a velocidade ideal de operação do insuflador, pois os métodos de cálculo da vazão de ar para salas limpas não mudaram em décadas.

O principal método utilizado, presente em IEST RP-12 (1993), consiste em tabelas, como a Tabela 8, recomendando a vazão de ar necessária em função da classe de limpeza do ar da sala. Conforme Jaisinghani (2003), esse documento de Recomendações Práticas em salas limpas foi publicado pelo IEST (Institute of Environmental Sciences and Technology) em 1993, sendo que os valores presentes na Tabela 8 não possuem base técnica rastreável.

Tabela 8 – Recomendações de trocas por hora de ar em salas limpas

Classe ISO 14644-1	Trocas/h	Veloc. Ar (m/s)	Regime de escoamento
4	360-540	0,5-0,6	laminar/misto
5	300-480	0,4-0,55	laminar/misto
6	240-400	0,3-0,45	misto/turbulento
7	150-240	0,2-0,35	turbulento
8	60-90	0,2-0,3	turbulento
9	5-48	0,1-0,2	turbulento

Fonte: Jaisinghani (2003).

Há décadas os engenheiros que projetam e operam salas limpas não realizam cálculos para determinar a vazão de ar a ser utilizada na sala limpa. Uma das variáveis mais importantes do sistema HVAC de uma sala limpa é na maioria das vezes simplesmente obtida de uma tabela, inicialmente desenvolvida com o objetivo de orientação para projetistas de salas limpas e não como regra de utilização e operação (Sun, 2008).

A eficiência energética, preocupação cada vez mais frequente, devido tanto ao seu viés econômico como ambiental, necessita de uma abordagem contendo um profundo embasamento científico desse assunto. Loomans *et al* (2019) afirmam que

na última década verificou-se que a grande maioria das salas limpas da Califórnia (EUA) estão operando com número de trocas de ar por hora acima do necessário, além de citarem que em muitos casos é possível atingir uma redução de até 30% no número de trocas de ar por hora e, conseqüentemente, uma economia de energia de até 66%, mantendo a sala limpa de acordo com sua classificação de classe de limpeza. A economia de energia pode ser calculada, segundo White (2002), aplicando a lei da afinidade ou lei da semelhança (*affinity law*), que relaciona a variação da velocidade de um motor com a variação de seu consumo de energia. Essa lei define que a variação do consumo de energia de um motor é proporcional ao cubo da variação da sua velocidade, conforme Equação (6).

$$\frac{P_1}{P_2} = \left(\frac{Q_1}{Q_2}\right)^3 \quad (6)$$

Onde P é o consumo de energia em W e Q é a vazão de ar movimentada pelo insuflador em m^3/s .

Algumas variáveis, segundo Jaisinghani (2003), que acarretam comprovada influência na qualidade do ar na sala e, conseqüentemente, na vazão de ar necessária e no desempenho do sistema HVAC da sala limpa, são apresentadas na Figura 14. Pode-se observar que recomendações como as constantes na Tabela 8 levam em consideração apenas as classes de limpeza, ignorando as variáveis associadas à operação da sala limpa, como a taxa de geração de partículas, qualidade do ar externo e eficiências dos filtros.

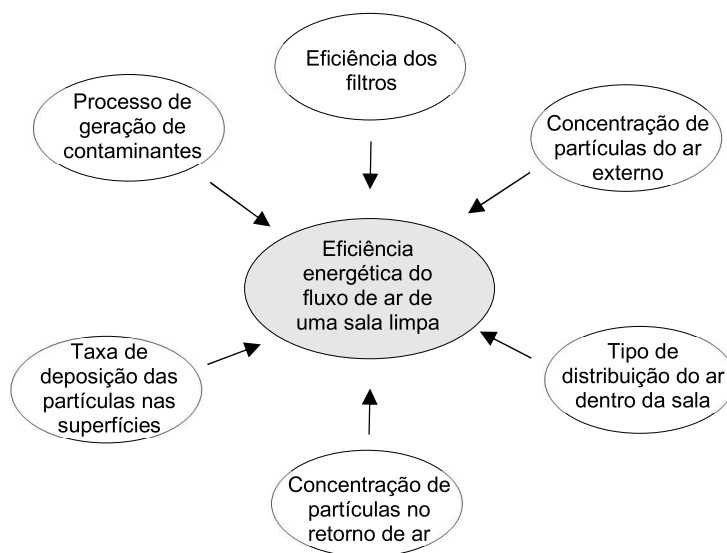
Existem diversas maneiras de se implementar uma redução na taxa de trocas de ar por hora, visando uma economia de energia e mantendo o ar da sala limpa dentro dos limites de impurezas determinados na norma NBR ISO 14644-1, de acordo com sua classe de limpeza.

O insuflamento de ar ultra limpo em salas limpas sob demanda (DCF - *Demand-Controlled Filtration*) trata-se um novo conceito proposto em alguns artigos nos últimos anos, como Loomans *et al.* (2020), Loomans *et al.* (2019), Ogunsola *et al.* (2019) e Molenaar (2017), como uma forma eficaz de redução do consumo de energia do HVAC, mais especificamente da etapa de insuflamento.

Esses artigos analisam dois métodos de insuflamento sob demanda:

- 1) *Fine-tuning*: Consiste em fixar um ou mais contadores de partículas na sala limpa para monitorar em tempo real a qualidade do ar. Os valores medidos de concentração de partículas modulam a velocidade do insuflador do sistema HVAC de acordo com a necessidade (Loomans *et al.* 2019). Porém, tais contadores de partículas são instrumentos de altíssimo custo e vida útil do seu feixe de laser limitada, o que torna extremamente onerosa sua utilização contínua e permanente.
- 2) DCF baseado em ocupação: O segundo método consiste em controlar a taxa de trocas por hora em função apenas da ocupação da sala. Onde sensores detectam em tempo real a presença ou não de pessoas ou ainda a quantidade de pessoas para modular a taxa de trocas de ar por hora. A desvantagem dessa técnica consiste em não levar em consideração a contaminação gerada pelas máquinas e processo, pois estes possuem, dependendo do tipo, taxas de geração de partículas semelhantes ou até maiores se comparadas às pessoas.

Figura 14 – Características que influenciam na qualidade do ar em salas limpas



Fonte: Adaptado de Jaisinghani (2003).

A empresa britânica EECO2 comercializa um produto denominado ICCS - *Intelligent Cleanroom Control System* (ICCS, 2020). Consiste na aplicação do método de controle do insuflamento sob demanda supracitado denominado *fine-tuning*. A

empresa anuncia a possibilidade de redução de energia de um sistema HVAC de uma sala limpa em até 60%.

Em síntese, um contador de partículas óptico de alta precisão é instalado em um ponto da sala, cuja função é monitorar em tempo real a concentração de partículas na sala limpa. O ICCS registra os valores lidos e comunica-se com o sistema de controle do HVAC já existente da sala limpa, em que uma camada intermediária baseada em controle adaptativo recomenda o aumento ou redução da velocidade do insuflador, mantendo continuamente a concentração de partículas na sala abaixo do limite definido em norma. O valor limite é configurável. Outros limites intermediários, ao serem superados, geram alarmes, sendo também configuráveis.

3.6 CONSIDERAÇÕES FINAIS

Para que um sistema HVAC seja controlado de maneira eficiente, o insuflador precisa operar com uma velocidade condizente com a qualidade do ar no interior da sala limpa. A qualidade do ar pode ser mensurada indiretamente por meio de um modelo de estimativa de concentração de partículas. Os estudos mais promissores - Xu (2003), Sun (2010) e Zhou (2017) - apontam a utilização de uma modelagem fenomenológica, empregando o princípio do balanço de massa das partículas que entram e saem da sala limpa, correlacionando com a taxa de trocas de ar ou a vazão de ar insuflada dentro da sala limpa. Fenômenos físicos aliados ao conhecimento do processo dão origem aos modelos desenvolvidos pelos autores supracitados, podendo ser estes modelos classificados como do tipo caixa cinza.

Um modelo que seja capaz de estimar a concentração de partículas dentro de uma sala limpa, quando desenvolvido com acurácia, utilizando os princípios citados, pode ser incorporado a um sistema de controle do HVAC da respectiva sala limpa. Pode-se considerar como um terceiro método de controle do insuflamento por demanda (DCF), além dos dois métodos citados na seção anterior. Tendo como consequência uma provável melhoria na eficiência energética do sistema HVAC, pois o objetivo de seu sistema de controle passa a ser então, além de manter os níveis adequados de temperatura, umidade e pressão, controlar a velocidade do insuflador para manter também a quantidade de partículas dentro de uma certa faixa de valores, adequada com a sua classe de limpeza definida pela norma NBR ISO 14644-1.

Após a revisão da bibliografia, foram encontrados poucos trabalhos que implementam algum tipo de estimador de quantidade/concentração de partículas em salas limpas e que sugira a utilização dessa variável para realimentar a malha de controle de um sistema HVAC.

Zhou (2017) compara 4 modelos que calculam a concentração média de partículas em uma sala limpa baseados na distribuição uniforme das partículas e em equações de balanço de massa. Os autores modificam um dos modelos para incluir alguns parâmetros, como as eficiências do sistema de filtragem e do sistema de ventilação e conclui que influenciam fortemente na precisão da estimativa da concentração de partículas na sala limpa.

Loomans *et al.* (2019) utilizam um modelo ainda mais simplificado. Desenvolvem um estudo de caso em que propõem que se considere o número de pessoas dentro da sala limpa como uma variável a ser inserida no modelo. Ambos artigos citados concluem que modelos, mesmo simplificados, podem ser utilizados para se determinar a mínima taxa de troca de ar necessária para atender a classe da sala limpa, classificada de acordo com a norma ISO 14644-1, havendo a possibilidade então de redução do consumo de energia do sistema HVAC.

Verificou-se que os modelos estudados por Zhou (2017) e Loomans *et al.* (2019) apresentam margem para aprofundamento de seus desenvolvimentos, como o detalhamento quanto à geração de partículas, que pode ser a partir de pessoas, máquinas em operação e/ou resultado do processo e dos materiais movimentados.

Considerando o que foi apresentado, infere-se que o principal motivo para que não existam trabalhos acadêmicos que realimentem a malha de controle do HVAC com a concentração de partículas mensuradas *online* seja a dificuldade de se estimar uma variável que tenha um comportamento e distribuição espacial complexas e que seja dependente de diversos fatores, como direção e velocidade do ar, volumes de ar reciclado e renovado que circula na sala, qualidade e estado dos filtros, identificação das fontes geradoras de contaminação do ar, entre outras características e propriedades que podem ser verificadas com alto nível de detalhamento em Xu (2014).

A Tabela 9 apresenta um resumo dos principais estudos e aplicações referentes ao monitoramento de concentração de partículas e eficiência energética em salas limpas.

Tabela 9 – Estudos e produtos que abordam concentração de partículas e economia de energia

Autor	Indústria	Aplicação e características
Xu (2003)	Semicondutores	Proposição de um novo modelo para estimação de concentração de partículas em salas limpas
Loomans <i>et al.</i> (2019)	Farmacêutica	Obtenção de redução de consumo de energia do sistema HVAC ao associar velocidade do insuflador com a ocupação da sala
Sun (2010)	Semicondutores	Acréscimo da deposição de partículas como um parâmetro adicional ao modelo de concentração de partículas
Xu (2014)	Semicondutores	Estudo detalhado sobre as fontes contaminantes geradoras de partículas em uma sala limpa e sua relação com o insuflamento
Zhou (2017)	Semicondutores	Comparação entre modelos de concentração de partículas existentes na literatura e proposta de inclusão do parâmetro eficiência de ventilação
Pereira (2008)	Hospitalar	Estimação de concentração de partículas em salas cirúrgicas relacionando ao número de pessoas, aos processos envolvidos e ao consumo de energia de diferentes aparelhos de ar condicionado e ventilação
Loomans <i>et al.</i> (2020)	Farmacêutica	Estudo dos efeitos da redução da ventilação à redução da pressão positiva mínima necessária à sala limpa e à melhoria da eficiência energética
Ogunsola <i>et al.</i> (2019)	Farmacêutica	Em função da geração de partículas em cada etapa de uma indústria farmacêutica, propõe redução do insuflamento para cada etapa do processo industrial
Molenaar (2017)	Farmacêutica	Proposta de melhoria da eficiência da ventilação associada à redução da velocidade do insuflamento para economia de energia
Mathew (2010)	Semicondutores	Compilação de diversos resultados obtidos por indústrias que implementaram algum método que visasse uma redução no consumo de energia do sistema HVAC
Levy (2015)	Laboratórios de pesquisa	Aplicação de redução da velocidade do insuflador em laboratórios de pesquisa em uma universidade proporcionaram uma economia de U\$ 20 mil anuais
ICCS (2020)	Diversas	Produto da empresa britânica ECCO2. Utiliza um contador de partículas óptico que monitora em tempo real a concentração de partículas na sala limpa e modula a velocidade do insuflador. Anuncia uma possível redução de até 60% no consumo de energia

Fonte: Elaborado pelo autor.

4 METODOLOGIA E RESULTADOS PRELIMINARES

Nesta seção são apresentadas as ferramentas, as técnicas e procedimentos que serão utilizados para cumprir com os objetivos deste estudo. Os *softwares* utilizados para desenvolver cada uma das etapas do trabalho serão descritos, uma vez citadas as técnicas necessárias na seção de fundamentação teórica.

4.1 MODELAGEM DO SENSOR POR SOFTWARE

Após uma extensa revisão bibliográfica, buscou-se uma modelagem semiempírica (caixa cinza) do sensor por *software*, por tratar-se de um modelo simplificado, de baixo custo computacional e que apresenta um ótimo resultado na representação do comportamento da concentração de partículas em salas limpas.

4.1.1 Modelo de estimação de concentração de partículas

Segundo Sun (2010), modelos matemáticos, que estimam a concentração de partículas no interior de uma sala limpa, apresentam-se como um método com um embasamento científico maior para determinar a taxa de trocas por hora do que as recomendações apresentadas na Tabela 8. O resultado da estimação do modelo pode auxiliar o operador de sala limpa a ajustar a velocidade do insuflador para um número de trocas de ar suficiente, de acordo com a utilização e ocupação da sala, mantendo a qualidade do ar abaixo dos limites estabelecidos em norma e apresentados na Tabela 2.

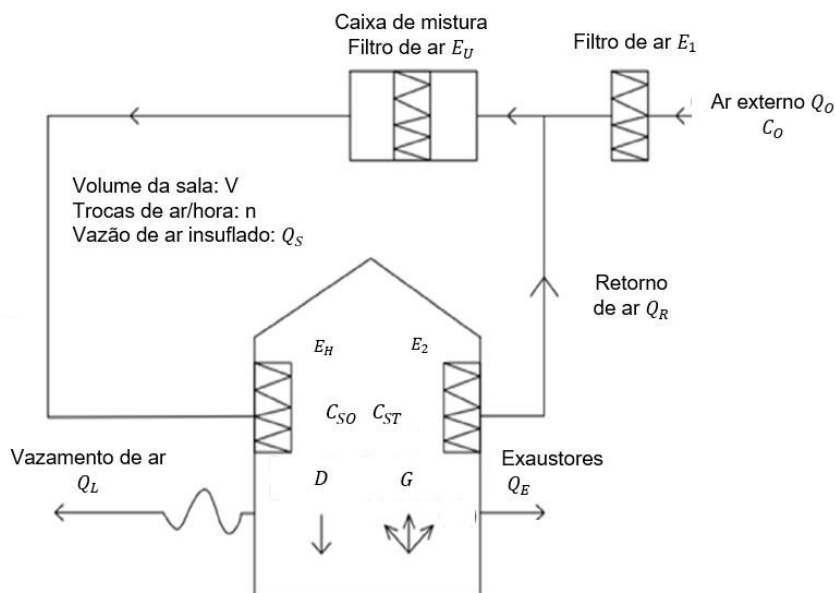
Diversos modelos que relacionam concentração de partículas com taxa de trocas de ar por hora foram publicados na literatura, baseando-se no conceito de balanço de massa e nas seguintes hipóteses:

- a) Concentração de contaminantes seja uniforme no ambiente
- b) Mistura homogênea do ar

Os modelos baseiam-se no princípio básico de funcionamento de uma sala limpa com regime de escoamento turbulento: A redução dos contaminantes na sala é possível devido à diluição do ar, *i.e.*, a inserção de ar ultra limpo pelo insuflador e a

retirada de ar contaminado da sala através da tubulação de retorno. A Figura 15 apresenta um diagrama de configuração básica do fluxo de ar que ilustra todos os parâmetros envolvidos no processo.

Figura 15 – Configuração básica do fluxo de ar em salas limpas



Fonte: Adaptado de Zhou (2017).

Onde:

V = Volume da sala (m^3)

Q_o = Vazão de ar externo (m^3/h)

Q_s = Vazão de ar insuflado na sala (m^3/h)

Q_R = Vazão de ar de retorno (m^3/h)

Q_E = Vazão de ar nos exaustores (m^3/h)

Q_L = Vazão de ar de escape nas portas e frestas (m^3/h)

C_s = Concentração de partículas no interior da sala (partículas/ m^3)

C_o = Concentração de partículas no exterior (partículas/ m^3)

E_1 = Eficiência do filtro grosso de ar externo

E_2 = Eficiência do filtro do retorno

E_U = Eficiência do filtro médio de ar do sistema HVAC

E_H = Eficiência do filtro fino (HEPA ou ULPA) de ar

ε_v = Fator de eficiência de ventilação do sistema (razão entre a concentração de partículas no interior da sala e no retorno de ar)

G = Taxa de geração de partículas (partículas/ m^3h)

D = Taxa de deposição de partículas (partículas/ m^3h)

r = Razão entre o ar de retorno e o externo

n = Número de trocas de ar por hora

t = Tempo (h)

Uma relação matemática pode ser então estabelecida, resultando em um modelo que relacione a taxa de trocas de ar por hora com a concentração de partículas no ar da sala.

Nas últimas décadas, vários modelos matemáticos foram propostos em Morrison (1973), Brown *et al.* (1986), Jaisinghani (2003). Nos últimos anos, houve uma evolução nos modelos, tornando-os mais descritivos, uma vez que foram adicionadas outras variáveis significativas do processo. Como consequência, sendo mais eficientes e precisos, como os modelos definidos em Xu (2003), Sun (2010) e Zhou (2017), que acrescentaram respectivamente as seguintes variáveis: fatores de eficiência geral dos filtros, taxa de deposição de partículas e fator de eficiência do sistema de ventilação.

O modelo de concentração de partículas de Zhou (2017) trata-se do modelo mais completo e detalhado encontrado atualmente na literatura, pois utiliza grande parte dos parâmetros presentes em Sun (2010) e Xu (2003). As diferenças entre os 3 modelos encontram-se na tabela 10:

Tabela 10 – Comparação entre os 3 modelos de estimação de concentração de partículas

Parâmetros/Modelos	Zhou (2017)	Sun (2010)	Xu (2003)
Fatores de eficiência geral dos filtros	sim	não	Sim
Taxa de deposição	sim	sim	não
Fator de eficiência de ventilação	sim	não	Não
Variáveis incluídas	$C_{so}, C_o, n, t, r, G, D, \eta_n, \eta_r, \varepsilon_v$	$C_{so}, C_o, n, t, r, G, D, E_U, E_H$	$C_{so}, C_o, n, t, r, G, \eta_n, \eta_r$

Fonte: Adaptado de Zhou (2017).

A partir das definições acima e dos parâmetros encontrados na Figura 15, torna-se possível a modelagem de um estimador de concentração de partículas em salas limpas.

4.1.1.1 Síntese do modelo de Zhou

Conforme seção anterior, o modelo encontrado em Zhou (2017) apresenta o maior número de parâmetros. Segue abaixo uma síntese do modelo.

Uma equação de balanço de massa das partículas no interior da sala pode ser estabelecida como:

$$V \frac{dC_s}{dt} = a + b - c - d \quad (7)$$

Onde:

a = massa de partículas que entram na sala por unidade de tempo

b = massa de partículas geradas internamente por unidade de tempo

c = massa de partículas que saem da sala por unidade de tempo

d = massa de partículas removidas por deposição por unidade de tempo

Analisando a Figura 15, a Equação 7 acima pode ser descrita como:

$$V \frac{dC_s}{dt} = [Q_o C_o (1 - \eta_n) + Q_R \varepsilon_v C_s (1 - \eta_r) + GV] - [Q_R C_s + Q_E \varepsilon_v C_s + Q_L \varepsilon_v C_s + DV] \quad (8)$$

Definiu-se η_n e η_r como as eficiências gerais dos filtros de insuflamento e de retorno:

$$\eta_n = 1 - (1 - E_1)(1 - E_U)(1 - E_H) \quad (9)$$

$$\eta_r = 1 - (1 - E_2)(1 - E_U)(1 - E_H) \quad (10)$$

A partir da relação entre as vazões de ar que entram e saem da sala:

$$Q_s = Q_R + Q_E + Q_L \quad (11)$$

Tem-se:

$$V \frac{dC_s}{dt} = [\varepsilon_v Q_R (1 - \eta_r) - \varepsilon_v Q_s] C_s + [Q_o C_o (1 - \eta_n) + (G - D)V] \quad (12)$$

Definindo a relação entre a vazão de insuflamento (Q_s) com o volume de ar da sala (V) e o número de trocas de ar por hora (n), tem-se a Equação 13. Definindo r como a relação entre o ar recirculante e o ar externo, tem-se a Equação 14:

$$Q_s = nV \quad (13)$$

$$r = \frac{Q_R}{Q_s} \Rightarrow Q_R = nVr \quad (14)$$

$$(1 - r) = \frac{Q_o}{Q_s} \Rightarrow Q_o = nV(1 - r) \quad (15)$$

Resulta em:

$$\frac{dC_s}{dt} = [\varepsilon_v r(1 - \eta_r) - \varepsilon_v]nC_s + \left[(1 - r)(1 - \eta_n) + \frac{(G - D)}{C_o n} \right] C_o n \quad (16)$$

Definindo α e β :

$$[\varepsilon_v r(1 - \eta_r) - \varepsilon_v] = -\alpha \quad (17)$$

$$(1 - r)(1 - \eta_n) + \frac{(G - D)}{C_o n} = \beta \quad (18)$$

Tem-se:

$$\frac{dC_s}{dt} = -\alpha n C_s + \beta n C_o \quad (19)$$

$$\frac{dC_s}{\beta C_o - \alpha C_s} = n dt \quad (20)$$

Considerando que a concentração de partículas varia entre uma quantidade inicial C_{SO} e uma quantidade final C_{ST} em um intervalo de tempo t , então:

$$\int_{C_{SO}}^{C_{ST}} \frac{dC_s}{\beta C_o - \alpha C_s} = \int_0^t n dt \quad (21)$$

$$-\frac{1}{\alpha} \ln(\beta C_o - \alpha C_s) \Big|_{C_{SO}}^{C_{ST}} = nt \quad (22)$$

$$\ln(\beta C_o - \alpha C_s) \Big|_{C_{SO}}^{C_{ST}} = -\alpha nt \quad (23)$$

$$\ln(\beta C_o - \alpha C_{ST}) - \ln(\beta C_o - \alpha C_{SO}) = -\alpha nt \quad (24)$$

$$\ln \frac{(\beta C_o - \alpha C_{ST})}{(\beta C_o - \alpha C_{SO})} = -\alpha nt \quad (25)$$

Após manipulações algébricas, chega-se à Equação 26, sendo um modelo simplificado capaz de estimar a concentração de partículas no interior da sala limpa em função do tempo (t) e de outros parâmetros do sistema HVAC, como o número de trocas por hora (n).

$$C_{ST} = \left(C_{SO} - \left(\frac{\beta}{\alpha} \right) C_o \right) e^{-\alpha n t} + \left(\frac{\beta}{\alpha} \right) C_o \quad (26)$$

Sendo: α e β definidos nas Equações 17 e 18, C_o a concentração de partículas no exterior, C_{SO} a concentração de partículas inicial na sala ($t = 0$), e C_{ST} a concentração de partículas a ser estimada na sala no instante t .

4.1.1.2 Novo modelo proposto

Após uma revisão bibliográfica sobre o comportamento dinâmico de partículas em salas limpas, bem como medições realizadas com contadores de partículas ópticos, desenvolveu-se um novo modelo matemático, mais completo e descritivo em relação ao proposto por Zhou, pois foram acrescentadas algumas variáveis referentes à geração de partículas no interior da sala limpa.

A geração de partículas na sala limpa é representada no modelo acima pelo parâmetro G . Verificou-se que esse parâmetro poderia ser desmembrado em outros 4 parâmetros, melhorando a precisão do modelo, sendo:

- G_p = Taxa de geração de partículas gerada por uma pessoa (partículas/m³h)
- G_m = Taxa de geração de partículas gerada por uma máquina (partículas/m³h)
- n_p = Número de pessoas na sala
- n_m = Número de máquinas na sala

Dessa forma, o modelo passa a ser o seguinte, descrito na Equação 27, tendo os parâmetros α e β descritos nas Equações 28 e 29.

$$C_{ST} = \left(C_{SO} - \left(\frac{\beta}{\alpha} \right) C_o \right) e^{-\alpha n t} + \left(\frac{\beta}{\alpha} \right) C_o \quad (27)$$

$$\alpha = \varepsilon_v - \varepsilon_v r (1 - \eta_r) \quad (28)$$

$$\beta = (1 - r)(1 - \eta_n) + \frac{(G_p n_p G_m n_m - D)}{C_o n} \quad (29)$$

4.1.2 Estudo de caso do modelo para determinação de seus parâmetros

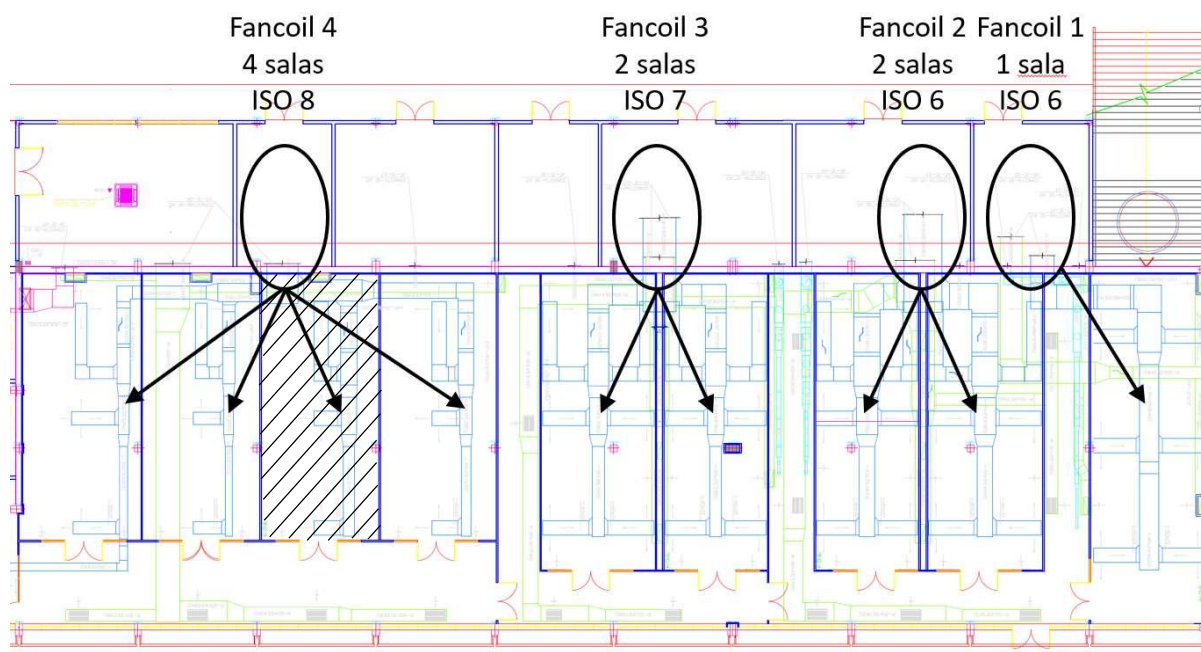
4.1.2.1 Características da sala limpa utilizada no estudo de caso

A fim de se verificar o funcionamento do modelo de estimação de concentração de partículas, este foi aplicado em uma das 9 salas limpas pertencentes ao Instituto Tecnológico itt Chip, localizado no campus da UNISINOS em São Leopoldo-RS.

As 9 salas são insufladas com ar ultra limpo a partir de 4 insufladores distintos, também chamados de *fancoils*, enumerados de 1 a 4. Os *fancoils* 1 e 2 insuflam o ar para 3 salas classificadas como Classe 6 pela norma NBR ISO 14644-1, enquanto o *fancoil* 3 corresponde à 2 salas Classe 7. Por fim, o *fancoil* 4 corresponde a 4 salas Classe 8, conforme ilustrado pela Figura 16.

A sala limpa utilizada no estudo de caso é uma das que são insufladas pelo *fancoil* 4, classificada como Classe 8 pela norma NBR ISO 14644-1, em destaque na Figura 16. Além disso, a sala possui as seguintes dimensões: 11x4,8x2,9m.

Figura 16 – Configuração das salas limpas do instituto itt Chip da UNISINOS



Fonte: Adaptado de Santos (2019).

O sistema HVAC do itt Chip possui as seguintes características de projeto apresentadas na Tabela 11, tendo uma faixa de operação com valores mínimos e

máximo de taxa de trocas de ar por hora diferente para cada classe de qualidade do ar da sala limpa.

Tabela 11 – Parâmetros de projeto das salas limpas do itt Chip

Classe ISO 14644-1	Nº de salas	Insuflador (<i>fancoil</i>)	trocas/h mínimo	trocas/h máximo
6	1	FC-1	15	60
6	2	FC-2	15	60
7	2	FC-3	10	40
8	4	FC-4	5	20

Fonte: Elaborado pelo autor.

O *fancoil* FC-4 correspondente à sala limpa do estudo de caso, denominada de Laboratório de Caracterização Física, possui a capacidade de fornecer ar ultra limpo à sala o equivalente a uma faixa de trocas de ar por hora (ACR) – parâmetro n do modelo - situada entre 5 e 20. Ao consultar o setpoint do sistema de controle do sistema HVAC, verificou-se que está fixado em 8 trocas de ar por hora, permanentemente e independentemente do número de pessoas ou do processo que está sendo desenvolvido na sala.

4.1.2.2 Determinação dos parâmetros do modelo

Os parâmetros operacionais do sistema HVAC da sala limpa utilizados no modelo são: $n = 8$, $r = 0,9$, $E_1 = 0,5$ (Filtro tipo Grosso Classe G3), $E_2 = 0$ (Filtro de retorno de ar: Não possui), $E_U = 0,75$ (Filtro tipo Fino Classe F8), $E_H = 0,9995$ (Filtro tipo HEPA Classe H13), $\varepsilon_v = 0,7$ (Regime de escoamento turbulento).

Os demais parâmetros do modelo, como C_o , D , G_p , e G_m necessitaram de estudos do comportamento das partículas e diversas medições da concentração de partículas com um instrumento denominado contador de partículas óptico, sendo utilizado o modelo P611 da marca Airys (Figura 17), capaz de medir partículas de diâmetro entre 0,3 μm e 5 μm . Neste estudo, foram consideradas em todas as medições as partículas de diâmetros entre 0,5 μm e 5 μm , devido à classificação da sala limpa ser ISO 8. A fabricante do instrumento de medição P611 recomenda sua utilização apenas dentro de salas limpas. Nas especificações desse contador de partículas, o fabricante aponta uma eficiência de 100% na contagem de partículas

com diâmetros maiores de 0,45 μm e de 50% nas partículas com diâmetro menores que 0,45 μm .

Figura 17 – Contador de partículas Airys P611



Fonte: Manual do produto Airys P611.

Para as medidas do ar externo (C_o), utilizou-se outro contador de partículas óptico, de baixo custo, OPCR1 da marca Alphasense (Figura 18), indicado pelo fabricante para se monitorar os níveis de poluição urbanos. A ficha técnica desse instrumento aponta um erro médio de 0,7% na contagem de partículas. A média de 10 medidas da qualidade do ar externo realizadas em 5 dias diferentes resultou em $C_o = 1,08 \times 10^7$ partículas/ m^3 . O desvio padrão da média, que exprime a incerteza em relação ao valor medido, foi de $\sigma_{pm} = 2,2 \times 10^5$ partículas/ m^3h , calculado através da equação abaixo:

$$\sigma_{pm} = \sqrt{\frac{\sum_{i=1}^n (y_i - \mu_y)^2}{(n - 1)}} \quad (30)$$

Onde:

μ_y = média das medidas

y_i = medida i , sendo $i = 1 \dots n$

n = número de medidas

Figura 18 – Contador de partículas Alphasense OPC R1



Fonte: Manual do produto Alphasense OPC R1.

A taxa de geração de partículas na sala gerada por uma pessoa (G_p) foi obtida com o intuito de simular diferentes cenários de utilização, a partir do cálculo da média de dezenas de medições realizadas com uma pessoa presente na sala com 4 intensidades distintas de movimentos. Os cenários estão enumerados e descritos abaixo:

- 1) Pessoa sentada movimento lentamente os braços;
- 2) Pessoa em pé e movimentando apenas os braços;
- 3) Pessoa caminhando lentamente pela sala;
- 4) Pessoa caminhando rapidamente pela sala;

O Quadro 2 apresenta o resultado das medições realizadas com o contador de partículas, sendo 5 medições para cada um dos 4 cenários. Realizou-se uma média das medições de cada cenário e após uma média geral para se determinar o valor da taxa média de geração de partículas por uma pessoa na sala limpa $G_p = 1,249 \times 10^6$ partículas/m³h, com desvio padrão da média de $3,162 \times 10^4$ partículas/m³h.

Quadro 2 – Ensaios realizados para a definição do valor de G_p

Cenário	Medidas (partículas/m ³) ($\times 10^6$)					G_p ($\times 10^6$)	Desvio padrão da média ($\times 10^4$)
	1	2	3	4	5		
1	0,79	0,62	0,73	0,66	0,7	0,71	2,96
2	1,15	0,99	0,92	0,97	1,11	1,03	4,36
3	1,39	1,4	1,45	1,51	1,38	1,43	2,43
4	2,01	1,68	1,91	1,72	1,82	1,83	6,06
Média						1,249	3,162

Fonte: Elaborado pelo autor.

A taxa de deposição de partículas nas superfícies (D) foi calculada com base em Sun (2010), que afirma que a referida taxa representa em média 8% da taxa de

geração de partículas da sala. Portanto, para o modelo considerou-se $D = 1 \times 10^5$ partículas/m³h.

Para se obter o parâmetro G_m , que consiste na taxa de geração de partículas geradas por uma máquina, houve a necessidade de um ambiente controlado, sem a presença de pessoas na sala limpa para que as medidas feitas com o contador de partículas fossem realizadas sem interferências. Portanto, montou-se em uma das salas limpas do itt Chip, denominada Laboratório de Caracterização Física, um sistema com 6 ventiladores de 12 cm de diâmetro instalados no chão, direcionados para o centro da sala, possibilitando a movimentação de partículas e assim se tornando agentes geradores de partículas suspensas no ar. Desse modo simulando máquinas, como por exemplo de solda, no caso de uma indústria de semicondutores.

A Figura 19 apresenta o sistema montado para a realização dos ensaios, sendo que no centro está localizado o contador de partículas para realizar as medições do impacto de cada um dos ventiladores (máquinas), enumerados de 1 a 6, na qualidade do ar na sala.

Figura 19 – Ambiente controlado montado na sala limpa




Fonte: Elaborado pelo autor.

Os ventiladores são acionados por um microcontrolador *Raspberry Pi* à distância, por meio de um smartphone, em uma interface WEB desenvolvida com o auxílio do *software Codesys 3.5*. Desse modo a sala poderia estar fechada e vazia

durante os ensaios realizados, sem interferências que pudessem afetar o fluxo de ar e a movimentação das partículas dentro da sala. O microcontrolador acoplado a uma placa de relés para acionamento dos ventiladores pode ser observado na Figura 20.

Figura 20 – Microcontrolador para acionar os ventiladores no ambiente controlado



Fonte: Elaborado pelo autor.

Um total de 12 ensaios foram feitos nesse ambiente controlado para se chegar a um valor médio da taxa de geração de partículas por uma máquina, $G_m = 1,511 \times 10^6$ partículas/m³h, com desvio padrão da média de $3,6 \times 10^4$ partículas/m³h, utilizando configurações e sequências diferentes de acionamento dos 6 ventiladores presentes na sala limpa, conforme Quadro 3.

Quadro 3 – Ensaios realizados para a definição do valor de G_m

Cenário	Ventiladores						G_m total ($\times 10^6$)	G_m ($\times 10^6$)
	1	2	3	4	5	6		
1	x						1,452	1,452
2		x					1,431	1,431
3			x				1,634	1,634
4				x			1,621	1,621
5					x		1,397	1,397
6						x	1,462	1,462
7	x					x	2,842	1,421
8		x			x		2,912	1,456
9			x	x			3,414	1,707
10	x		x		x		4,662	1,554
11		x		x		x	4,503	1,501
12	x	x	x	x	x	x	8,964	1,494
Média								1,511

Fonte: Elaborado pelo autor.

Outro parâmetro do modelo que precisou de um ambiente controlado para ser determinado com precisão foi C_{SO} , que é a concentração de partículas inicial da sala limpa. Com a sala vazia e nenhum equipamento ligado (em repouso), efetuou-se a medição da concentração de partículas suspensas no ar 5 vezes, em dias diferentes, cuja média resultou em $C_{SO} = 6,14 \times 10^4$ partículas/m³, com desvio padrão da média de $8,6 \times 10^2$.

4.1.3 Simulações realizadas com o modelo


Tendo todos os parâmetros do modelo, foi possível desenvolver um script em Matlab® R2018a para simular sua resposta de estimação da qualidade do ar na sala limpa frente às perturbações, representadas por variações na ocupação e utilização da sala ou ainda por alterações na taxa de trocas de ar por hora.

As simulações a seguir apresentam os resultados da estimação do modelo, durante o período de uma hora, para diversos níveis de ocupação da sala e de operação de máquinas. O número de pessoas na sala é definido por n_p e o número de máquinas em operação é definido por n_m . Todas as simulações consideram que em $t = 0$ a sala está em repouso, com uma concentração de partículas de $C_{SO} = 6,14 \times 10^4$ partículas/m³.

A simulação da Figura 21 foi executada considerando uma taxa de trocas de ar por hora (n) fixa igual a 8, para representar fidedignamente a operação da sala limpa do estudo de caso, facilitando a etapa de validação do modelo, presente na próxima seção. A Figura 21 apresenta o resultado do modelo para 4 cenários diferentes de ocupação e utilização.

Pode-se observar que o impacto na qualidade do ar no interior da sala limpa é proporcional ao número de pessoas presentes e à quantidade de máquinas ligadas. Mesmo com 2 pessoas na sala e 6 máquinas ligadas, a sala limpa ainda se mantém dentro do limite imposto pela norma ABNT NBR 14644-1, sendo que para a Classe 8, o limite é de $3,52 \times 10^6$ partículas/m³, conforme Tabela 2.

Figura 21 – Resultado da simulação do modelo de estimação de concentração de partículas em 4 cenários diferentes

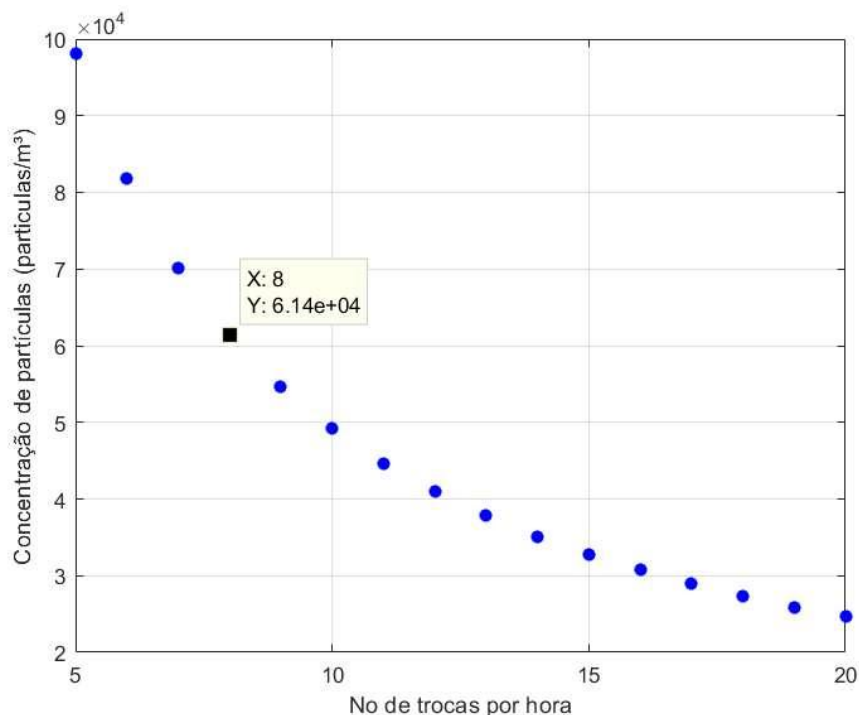


Fonte: Elaborado pelo autor.

Na simulação seguinte, Figura 22, verificou-se o comportamento da concentração de partículas em função do número de trocas de ar por hora (n), variando entre 5 e 20 e considerando a sala em repouso, *i.e.*, $n_p = 0$ e $n_m = 0$. O ponto marcado na figura corresponde à concentração de partículas na sala, considerando esta em repouso e com o número de trocas por hora igual a 8, que consiste no atual setpoint do sistema HVAC da sala limpa do itt Chip.

Pode-se observar que, considerando a sala em repouso, existe a possibilidade de se reduzir a taxa de trocas de ar por hora para o valor mínimo que o sistema HVAC dessa sala limpa suporta: $n = 5$, sem que a concentração de partículas ultrapasse o limite determinado em norma (1×10^5 partículas/m³, o que representa apenas 3% do limite de $3,52 \times 10^6$ partículas/m³). Isso implica em uma possível diminuição na velocidade do insuflador em 37,5%. De acordo com a Equação 6, resulta em uma redução no consumo de energia do insuflador de 75,6%.

Figura 22 – Resultado da simulação do modelo para uma faixa de valores de taxa de troca de ar por hora considerando a sala em repouso

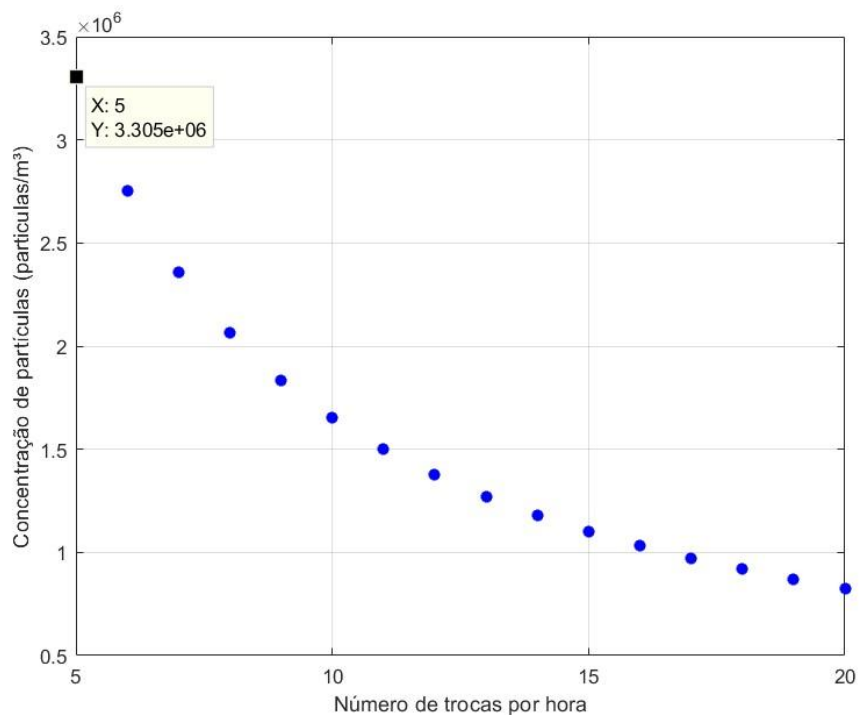


Fonte: Elaborado pelo autor.

Essa análise pode ser estendida para outros cenários de utilização da sala limpa, com o intuito de se verificar quantas pessoas podem estar presentes na sala e quantas máquinas podem estar em operação, mantendo a concentração de partículas dentro do limite supondo uma redução da taxa de trocas de ar por hora para $n = 5$. Na Figura 23 verifica-se que o maior nível de atividade da sala pode ser de até 2 pessoas e 1 máquina ligadas, representando 94% da concentração de partículas limite imposta pela norma.


Além disso, outra análise pode ser realizada, em que se pode verificar qual o limite de ocupação da sala, mantendo a concentração de partículas permitida pela norma e o atual valor de setpoint fixado em 8 para a taxa de trocas de ar por hora ($n = 8$). Na Figura 24 observa-se que o modelo estima $3,36 \times 10^6$ partículas/m³ com 8 pessoas e 6 máquinas em operação. Já com as máquinas desligadas, o modelo estima $3,3 \times 10^6$ partículas/m³ com 15 pessoas presentes na sala. Reiterando que o valor limite de concentração para uma sala Classe 8 é de $3,52 \times 10^6$ partículas/m³.

Figura 23 – Resultado da simulação do modelo para uma faixa de valores de taxa de troca de ar por hora considerando 2 pessoas e 1 máquina



Fonte: Elaborado pelo autor.


Figura 24 – Resultado da simulação do modelo para encontrar a maior taxa de ocupação com $n = 8$



Fonte: Elaborado pelo autor.

Uma outra simulação executada encontra-se na Figura 25. A estimação da concentração de partículas na sala limpa ao longo de um intervalo de uma hora, em que 4 cenários diferentes de utilização da sala limpa ocorrem, variando o número de pessoas (n_p) e de máquina ligadas (n_m). Essa forma de análise viabiliza ao operador da sala limpa conhecer antecipadamente qual o impacto na qualidade do ar cada alteração de cenário proporciona. Isto possibilita um aumento ou redução na taxa de trocas de ar por hora do sistema HVAC, caso necessário.

Figura 25 – Resultado da simulação do modelo para 4 diferentes cenários



Fonte: Elaborado pelo autor.

4.1.4 Validação do modelo de estimação de concentração de partículas

Com o objetivo de validar o modelo de estimação, diversos ensaios foram realizados com 20 diferentes cenários, variando n_p entre 0 e 2 e n_m entre 0 e 6. Foram realizadas 5 medições com o contador de partículas óptico em cada instante de tempo, desde o repouso em $t = 0$ até $t = 30$ minutos, repetindo-se a cada período de 5 minutos, para cada um dos cenários. O Quadro 4 compara o resultado da estimação

do modelo (C_e) com os resultados das médias das 5 medições feitas a cada instante de tempo, em cada um dos 20 cenários, no ambiente controlado (C_r). Essa passa a ser a base de dados de medições da sala limpa desse estudo de caso e será também utilizada na próxima seção dessa dissertação (Correção do modelo).


Quadro 4 – Comparativo entre valores medidos e estimados

Cenário	n_m	n_p	5 min		10 min		15 min	
			$C_r (x10^5)$	$C_e (x10^5)$	$C_r (x10^5)$	$C_e (x10^5)$	$C_r (x10^5)$	$C_e (x10^5)$
1	1	0	1,233	1,279	2,058	1,973	2,359	2,311
2	2	0	2,078	2,286	3,671	4,006	4,956	4,842
3	3	0	2,809	3,332	5,454	6,039	6,854	7,382
4	4	0	3,956	4,299	7,489	8,072	9,215	9,919
5	5	0	4,718	5,303	9,025	10,113	11,985	12,456
6	6	0	5,187	6,320	10,587	12,144	13,476	14,988
7	0	1	1,330	1,105	1,786	1,627	2,012	1,872
8	1	1	2,456	2,112	4,115	3,653	4,698	4,406
9	2	1	3,798	3,119	5,987	5,686	7,436	6,942
10	3	1	4,798	4,124	8,253	7,719	9,976	9,475
11	4	1	5,687	5,131	10,469	9,753	12,876	12,135
12	5	1	8,043	6,136	12,965	11,794	15,587	14,546
13	6	1	9,265	7,143	16,365	13,829	18,384	17,082
14	0	2	1,447	1,935	2,456	3,301	3,495	3,967
15	1	2	2,248	2,943	4,576	5,334	6,000	6,501
16	2	2	3,351	3,949	6,698	7,367	9,301	9,036
17	3	2	4,803	4,957	9,865	9,402	12,284	11,576
18	4	2	7,959	5,962	12,656	11,438	15,187	14,154
19	5	2	9,736	6,968	15,781	13,476	17,416	16,641
20	6	2	8,924	7,972	17,654	15,553	20,815	19,174
			20 min		25 min		30 min	
1	1	0	2,424	2,405	2,456	2,427	2,486	2,422
2	2	0	5,107	5,077	5,195	5,117	5,296	5,129
3	3	0	7,719	7,751	7,825	7,815	7,653	7,819
4	4	0	10,215	10,426	10,972	10,544	11,463	10,553
5	5	0	13,856	13,124	14,126	13,213	14,548	13,225
6	6	0	14,145	15,774	14,523	15,923	15,157	15,932
7	0	1	2,213	1,941	2,252	1,954	2,325	1,954
8	1	1	4,715	4,615	4,782	4,649	4,899	4,653
9	2	1	7,629	7,288	7,853	7,345	7,985	7,351
10	3	1	10,536	9,961	10,965	10,047	11,256	10,052
11	4	1	13,456	12,637	13,653	12,746	13,986	12,754
12	5	1	15,832	15,312	15,936	15,436	16,891	15,452
13	6	1	18,695	17,983	18,984	18,131	19,713	18,151
14	0	2	3,989	4,151	4,403	4,182	4,659	4,185
15	1	2	6,256	6,824	6,249	6,878	6,747	6,883
16	2	2	9,946	9,498	10,787	9,574	10,956	9,582
17	3	2	13,256	12,174	13,986	12,274	14,165	12,283
18	4	2	15,423	14,847	16,132	14,971	16,875	14,988
19	5	2	17,965	17,523	18,984	17,661	19,985	17,685
20	6	2	21,987	20,191	22,756	20,368	22,984	20,385

Fonte: Elaborado pelo autor.

Os ensaios foram limitados em 30 minutos pois nesse espaço de tempo a saída do modelo apresenta pelo menos 90% do valor de regime permanente, conforme observa-se na Figura 21. Utilizando os mesmos quatro cenários da Figura 25, a Figura 26 apresenta uma comparação entre os resultados do modelo de estimação e as medições realizadas com o contador de partículas presentes no Quadro 4.

Figura 26 – Comparação entre valores medidos e estimados pelo modelo para 4 diferentes cenários



Fonte: Elaborado pelo autor.

A ferramenta utilizada para quantificar a performance do modelo e para a sua validação foi ASTM D-5153-2019, um guia com recomendações para avaliação estatística de modelos de qualidade do ar de interiores, publicado pela *American Society for Testing and Materials*. Esse guia provê um conjunto de métricas que permitem avaliar o modelo comparando as concentrações de partículas estimadas (C_e) com as medidas (C_r). Fazem parte desse conjunto de métricas o coeficiente de correlação r , calculado pela Equação 31 e o Erro Médio Quadrático Normalizado (*NMSE-Normalized Mean Square Error*), obtido pela Equação 32, que consiste em uma medida da magnitude do erro de estimação relativo.

$$r = \frac{\sum_{i=1}^n [(C_{ri} - \bar{C}_r)(C_{ei} - \bar{C}_e)]}{\sqrt{\sum_{i=1}^n [(C_{ri} - \bar{C}_r)^2] [\sum_{i=1}^n (C_{ei} - \bar{C}_e)^2]}} \quad (31)$$

$$NMSE = \frac{\sum_{i=1}^n (C_{ei} - C_{ri})^2 / n}{[(\bar{C}_r)(\bar{C}_e)]} \quad (32)$$

Para que o modelo tenha uma boa performance de acordo com os critérios da ASTM D-5153-2019 e seja considerado um bom modelo, precisa conter:

- 1) $r \geq 0,9$
- 2) $NMSE \leq 0,25$.

Na Tabela 12 encontram-se os critérios calculados para cada um dos 20 cenários. Observa-se que o modelo representa bem o processo, pois em 12 cenários os critérios ficaram dentro dos intervalos recomendados (destacados em azul).

Tabela 12 – Avaliação estatística da qualidade do modelo

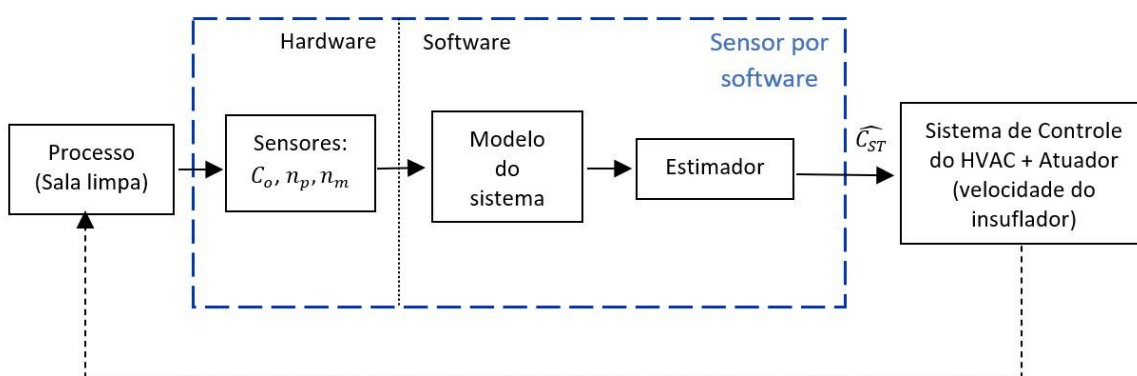
Cenário	r	$NMSE$
1	0,98	0,02
2	0,97	0,05
3	0,95	0,11
4	0,94	0,13
5	0,91	0,19
6	0,88	0,34
7	0,70	0,57
8	0,92	0,15
9	0,91	0,18
10	0,90	0,23
11	0,92	0,17
12	0,90	0,23
13	0,87	0,31
14	0,74	0,60
15	0,90	0,24
16	0,91	0,24
17	0,85	0,35
18	0,86	0,33
19	0,84	0,42
20	0,86	0,36

Fonte: Elaborado pelo autor.

Uma vez que o modelo demonstrou bons resultados, existe a possibilidade de, caso não se exija rigorismo na precisão e acuracidade do modelo, considerar que a modelagem do sensor por *software* está concluída após a etapa de validação.

Nesse caso, seu funcionamento pode ser explicado pelo diagrama de blocos da Figura 27. Os valores lidos pelos sensores físicos (*hardware*) são inseridos no modelo (etapa executada por *software*), possibilitando que uma estimação possa ser feita em um instante futuro (\widehat{C}_{ST}). O valor dessa estimação pode ser inserido no sistema de controle do HVAC para reconfigurar o *setpoint* da taxa de trocas por hora.

Figura 27 – Estrutura do sensor por *software*



Fonte: Elaborado pelo autor.

Porém, analisando a Tabela 12, observa-se que 8 cenários apresentam os índices estatísticos de performance fora da faixa recomendada, sendo que 2 deles (cenários 7 e 14) se destacam negativamente por possuírem os piores resultados. Uma das possíveis soluções para esse problema consiste em uma correção do modelo através do ajuste de seus parâmetros, implementada na próxima seção.

4.2 CORREÇÃO DO SENSOR POR SOFTWARE

Com o intuito de melhorar o desempenho do modelo, aplicou-se uma técnica de otimização não-linear com restrições para se ajustar alguns de seus parâmetros. Dentre os parâmetros do modelo, os que se encontram abaixo são os que apresentaram uma grande variação nos ensaios que levaram às determinações de seus valores médios, a partir das medições com o contador de partículas cuja metodologia descreveu-se na seção anterior. Observa-se os 5 referidos parâmetros e seus intervalos de valores mínimos e máximos abaixo:

- 1) $G_p : 710.562 \leq G_p \leq 1.838.562$
- 2) $G_m : 1.397.451 \leq G_m \leq 1.707.564$
- 3) $D : 56.584 \leq D \leq 146.756$
- 4) $C_{S0} : 51.541 \leq C_{S0} \leq 69.460$
- 5) $C_0 : 9.654.829 \leq C_0 \leq 11.287.652$

Para ajustar esses parâmetros, foram criadas 5 variáveis auxiliares ($G_{px}, G_{mx}, D_x, C_{S0x}, C_{0x}$), que multiplicam os parâmetros originais do modelo (G_p, G_m, D, C_{S0}, C_0). Os limites inferiores e superiores das 5 variáveis auxiliares são relativos a um valor unitário, proporcionais aos limites acima citados oriundos das medições com o contador de partículas, mas normalizados. Portanto:

- 1) $G_{px} : 0,732 \leq G_{px} \leq 1,304$
- 2) $G_{mx} : 0,924 \leq G_{mx} \leq 1,131$
- 3) $D_x : 0,569 \leq D_x \leq 1,468$
- 4) $C_{S0x} : 0,857 \leq C_{S0x} \leq 1,155$
- 5) $C_{0x} : 0,925 \leq C_{0x} \leq 1,081$

Portanto, o modelo para estimação da concentração de partículas passa a ser representado nas Equações 33, 34 e 35:

$$C_{ST} = \left(C_{S0} C_{S0x} - \left(\frac{\beta}{\alpha} \right) C_0 C_{0x} \right) e^{-\alpha t} + \left(\frac{\beta}{\alpha} \right) C_0 C_{0x} \quad (33)$$

$$[\varepsilon_v r(1 - \eta_r) - \varepsilon_v] = -\alpha \quad (34)$$

$$(1 - r)(1 - \eta_n) + \frac{(n_p G_p G_{px} + n_m G_m G_{mx} - DD_x)}{C_0 n} = \beta \quad (35)$$

A otimização do modelo foi obtida por meio da função *fmincon* do Matlab® R2018a, que encontra um vetor solução que minimiza uma certa função ou conjunto de funções $f(x)$, sujeito a restrições nos valores do vetor x . A função que precisa ser minimizada, representada pela Equação 36, corresponde ao erro absoluto que precisa ser minimizado, entre o valor da concentração de partículas estimado pelo modelo (\widehat{C}_{ST}) e o valor medido pelo contador de partículas na sala limpa (C_{med}), sendo esse último a base de dados de medição apresentada no Quadro 4.

Essa otimização é executada a cada instante de tempo ($t = 5; t = 10; t = 15; t = 20; t = 25$ e $t = 30$ minutos) e para cada um dos 20 cenários de utilização da sala limpa. O vetor x possui 5 elementos e correspondem aos parâmetros que se desejam corrigir. Seus intervalos de variação, que representam as restrições da função, são provenientes dos limites mínimos e máximos das 5 variáveis auxiliares ($G_{px}, G_{mx}, D_x, C_{SOx}, C_{0x}$) supracitadas, sendo $x_1 = G_{px}$, $x_2 = G_{mx}$, $x_3 = D_x$, $x_4 = C_{SOx}$, $x_5 = C_{0x}$.

$$\min_x abs(erro(x)) = |\widehat{C_{ST}} - C_{med}| \quad (36)$$

Sujeito a:

$$0,732 \leq x_1 \leq 1,304$$

$$0,924 \leq x_2 \leq 1,131$$

$$0,569 \leq x_3 \leq 1,468$$

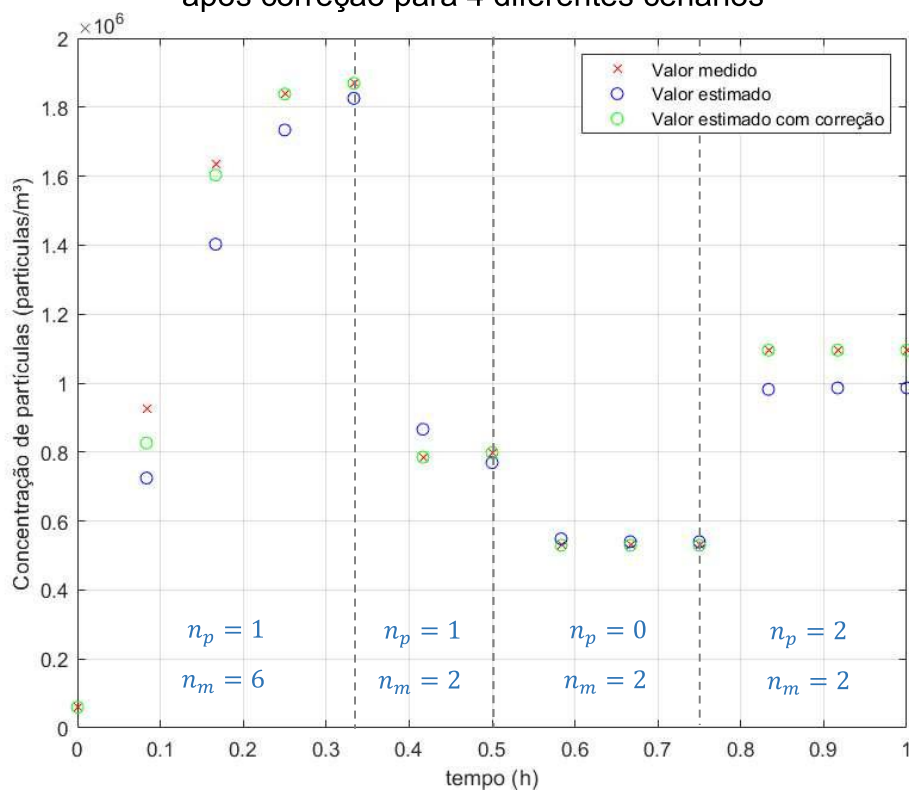
$$0,857 \leq x_4 \leq 1,155$$

$$0,925 \leq x_5 \leq 1,081$$

Ao incluir a função *fmincon* no *script* desenvolvido, para resolver o problema de otimização não-linear com restrições apresentado em (36), encontrou-se um conjunto de parâmetros $G_{px}, G_{mx}, D_x, C_{SOx}, C_{0x}$ diferentes para cada instante de tempo e para cada cenário diferente, resultando em 120 diferentes conjuntos de parâmetros. A Figura 28 compara os resultados do sensor por *software* antes e após a correção dos parâmetros com os valores medidos.


A Figura 29 apresenta os valores dos parâmetros, após o ajuste propiciado pela otimização, para cada instante de tempo em que ocorre uma estimação, para a mesma simulação contendo os 4 cenários da Figura 28. Enquanto a Figura 30 representa o erro quadrático existente entre os valores estimados pelo modelo antes e após as correções em relação aos valores medidos $(C_{med} - C_{est})^2$. Observa-se que foi possível reduzir o erro em percentuais de 50% a 95%, dependendo do instante e cenário, após a otimização que ajustou os parâmetros. Convém salientar que se não houvesse restrições nos parâmetros, uma otimização não-linear sem restrições reduziria o erro ainda mais, tornando-o praticamente nulo. Porém, isso resultaria possivelmente em parâmetros fora de uma faixa de valores comumente observadas no processo, podendo ser em alguns casos fisicamente irrealizáveis.

Figura 28 – Comparação entre valores medidos e estimados pelo modelo após correção para 4 diferentes cenários




Fonte: Elaborado pelo autor.

Figura 29 – Valores dos parâmetros após seus ajustes propiciados pela otimização



Fonte: Elaborado pelo autor.

Figura 30 – Sinal de erro do modelo antes e após o ajuste dos parâmetros



Fonte: Elaborado pelo autor.

Com o intuito de diminuir a quantidade de conjuntos de parâmetros, para reduzir o consumo computacional que a função de otimização não-linear com restrições demanda, apenas um conjunto de parâmetros foi definido para cada cenário, para qualquer instante de tempo. Assim consegue-se reduzir de 120 para 20 conjuntos de parâmetros.

A ferramenta utilizada para encontrar o conjunto mais adequado de parâmetros para cada cenário foi o método dos mínimos quadrados, apresentados na Tabela 13, além de uma nova análise estatística para cada um dos 20 cenários, considerando uma nova batelada de medições que substituíram os dados do Quadro 4.

Observa-se que houve uma melhora significativa nos critérios de desempenho r e $NMSE$ com os parâmetros ajustados, após o ajuste dos parâmetros, em comparação com a análise estatística feita anteriormente (Tabela 12). Para todos os cenários, agora os critérios r e $NMSE$ estão dentro dos intervalos recomendados, se aproximando com mais frequência dos valores ideais, que indicam um modelo que representa com mais exatidão o processo. Os valores ideais são: critério r próximo a 1 e critério $NMSE$ próximo a 0. Na Figura 31 encontra-se a comparação entre os


valores medidos e estimados após a correção dos parâmetros e obtenção do melhor conjunto de parâmetros para cada cenário.

Tabela 13 – Avaliação estatística do modelo após ajuste dos parâmetros

Cenário	r	$NMSE$	G_{px}	G_{py}	D_x	C_{SOx}	C_{Ox}
1	0,99	0,01	1	1	1,01	1,02	1,01
2	0,99	0,01	0,98	0,99	1,01	0,99	1,07
3	0,98	0,02	0,94	0,97	1,04	0,96	1,15
4	0,97	0,03	0,96	0,98	1,08	1	1,11
5	0,96	0,04	0,96	0,98	1,01	1,02	1,11
6	0,92	0,07	0,89	0,94	1,01	0,92	1,28
7	0,87	0,11	0,98	0,99	0,96	1	1,05
8	0,96	0,03	1,02	1	1,13	1,03	0,98
9	0,95	0,04	1,04	1,01	1,14	1,06	0,93
10	0,95	0,05	1,04	1,01	1,14	1,09	0,95
11	0,92	0,03	1,03	1	1,1	1,09	0,99
12	0,94	0,05	1,05	1,01	1,1	1,08	0,94
13	0,92	0,06	1,06	1,03	1,13	1,08	0,89
14	0,84	0,12	0,94	0,98	0,88	1	1,15
15	0,93	0,06	0,94	0,97	0,88	0,96	1,16
16	0,91	0,06	0,98	0,99	1,07	1,01	1,06
17	0,91	0,07	1,02	1	1,16	1,06	1
18	0,91	0,07	1,05	1,01	1,18	1,08	0,94
19	0,93	0,08	1,06	1,03	1,18	1,09	0,9
20	0,91	0,07	1,04	1	1,18	1,1	0,98

Fonte: Elaborado pelo autor.

Figura 31 – Comparação entre valores medidos e estimados pelo modelo após correção e obtenção do melhor conjunto de parâmetros

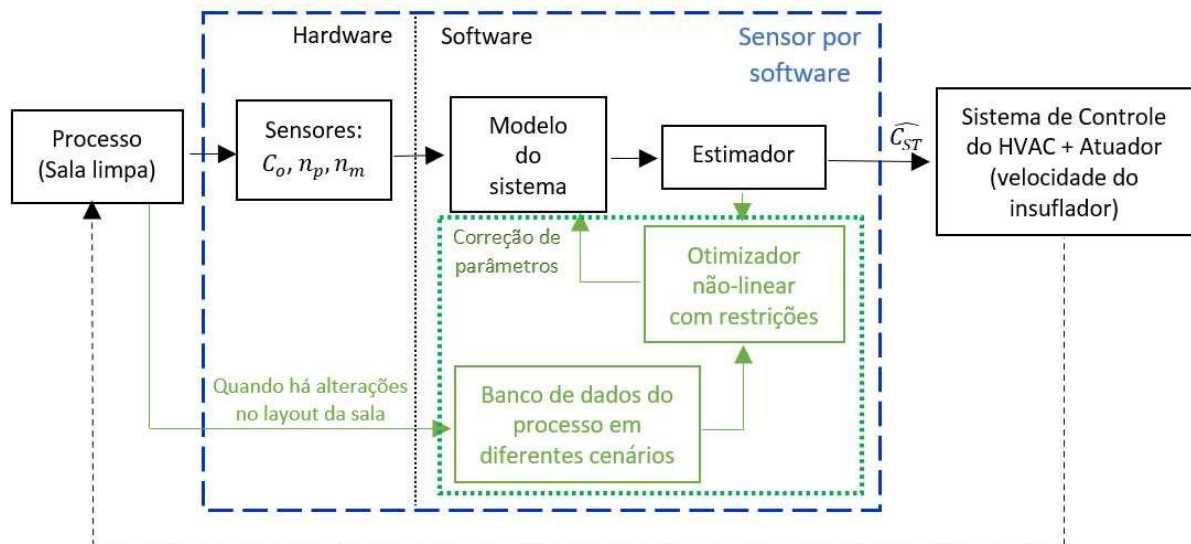


Fonte: Elaborado pelo autor.

4.2.1 Estrutura final do sensor por *software*

A estrutura do sensor por *software* pode ser visualizada na Figura 32, com a adição da etapa de correção dos parâmetros do modelo. As grandezas físicas que podem ser capturadas por sensores e inseridas em tempo real no modelo são: a qualidade do ar externo (C_o), em que pode ser utilizado um sensor de qualidade do ar de baixo custo; o número de pessoas na sala (n_p), que pode ser obtido por um sensor de presença na porta da sala; o número de máquinas ligadas (n_m), que pode ser obtido por sensores instalados nas máquinas.

Figura 32 – Estrutura do sensor por *software* com correção de parâmetros



Fonte: Elaborado pelo autor.

Neste estudo, foi proposto e validado um sensor por *software* onde os parâmetros são inseridos de forma manual. Para que ele opere de forma automática, os sensores supracitados precisam ser instalados na sala limpa e a saída do sensor por *software* acoplada ao sistema de controle do HVAC da sala limpa, de modo a modular a velocidade do insuflador. Além disso, também os parâmetros r , razão entre o ar de retorno e o ar externo (% de abertura do *damp*er do sistema HVAC) e a taxa de trocas de ar por hora (n) podem ser obtidos do sistema de controle do HVAC e inseridos no modelo constantemente, para que se obtenha uma estimativa *online*.

Para o sensor por *software*, quando não automatizado, não ter sua precisão reduzida ao longo do tempo, alguns parâmetros do seu modelo precisam ser

atualizados manualmente, como a eficiência dos filtros que decaem com o tempo, a razão r entre o ar de retorno e o ar externo (% de abertura do *damper* do sistema HVAC) ou ainda a taxa de trocas de ar por hora (n).

Caso seja feita uma alteração em uma máquina ou no layout da sala, a taxa de geração de partículas média por uma máquina (G_m) pode também se modificar, devido às alterações no fluxo de ar no interior da sala. Nesse caso, novos ensaios precisam ser realizados para determinar o parâmetro G_m e para atualizar a base de dados do processo, de modo que possa ser feita uma nova atualização dos parâmetros do modelo.

Esse sensor por *software* pode ser aplicado em outras salas limpas, desde que seja feita uma série de ensaios para se criar uma base de dados, com medições das concentrações de partículas ao longo de um certo intervalo de tempo para cada cenário diferente, para se determinar os parâmetros G_m e C_{SO} , além de todos os outros parâmetros do sistema HVAC da sala limpa que precisam ser inseridos no modelo.

4.3 SENSOR POR SOFTWARE COM FILTRO DE KALMAN

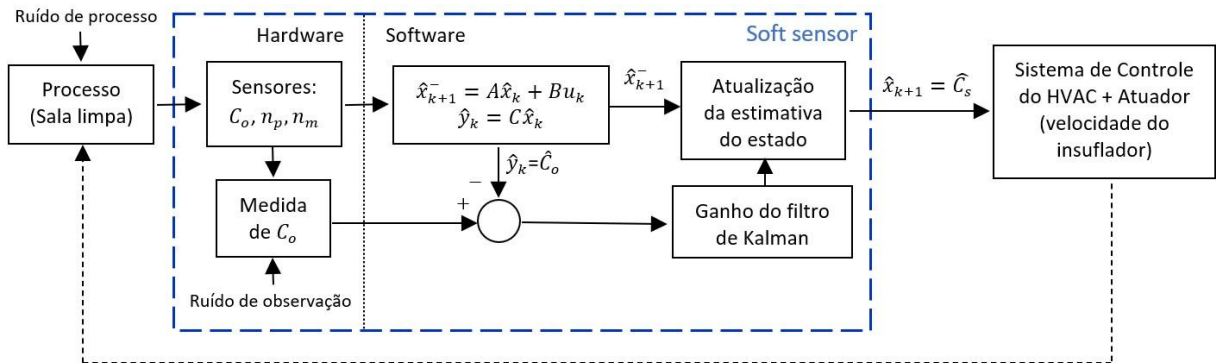
Uma outra abordagem pode ser utilizada no desenvolvimento de um sensor por *software*, por exemplo, a estimação de estados, que consiste na estimativa de um estado atual do sistema que apresenta dificuldade ou impossibilidade de medição, baseado no valor atual da saída do sistema, possível de ser medido, além dos valores passados dos estados e da saída.

O filtro de Kalman costuma ser um importante aliado à estimação de estados de sistemas lineares, pois busca a correção à resposta de um determinado sistema a partir de variáveis conhecidas relacionadas a ele. Assim, é possível realizar uma estimação do estado com um mínimo grau de incerteza, mesmo com ruídos de processo e de observação.

O objetivo é estimar a concentração de partículas no interior da sala limpa (C_s) a partir das medidas de concentração de partículas do ar externo (C_o). Um contador de partículas óptico de baixo custo, como o Alphasense OPCR1, pode ser utilizado para medir a qualidade do ar externo *online* pois não é necessário a esse instrumento possuir uma alta precisão na contagem de partículas, devido ao ar externo conter uma alta quantidade de partículas por m^3 , da ordem de 10^7 . Mesmo com presença de ruído de natureza estocástica, como o ruído branco, no processo e/ou na medida, a

estimativa de estado com filtro de Kalman é ótima. A representação em diagrama de blocos do sensor por *software* com filtro de Kalman encontra-se abaixo:

Figura 33 – Estrutura do sensor por *software* com filtro de Kalman



Fonte: Elaborado pelo autor.

O modelo do sistema precisa ser representado em espaço de estados, em que a saída do sistema corresponde à concentração de partículas no ar externo C_o , além de um dos estados que se deseja estimar x_{k+1} corresponde à concentração de partículas no interior da sala C_s .

Observa-se na Figura 33 que, a partir do modelo do sistema em espaço de estados, é realizada uma estimativa *a priori* \hat{x}_{k+1}^- e uma estimativa da saída \hat{y}_k . Um ganho K denominado ganho de Kalman é aplicado, proporcional ao erro entre a saída estimada \hat{C}_o e a medida C_o , a uma atualização da estimativa, resultando em uma estimativa *a posteriori* $\hat{x}_{k+1} = \hat{C}_s$, que pode ser utilizada como parâmetro para alterar o *setpoint* da velocidade do insuflador, no sistema de controle do HVAC.

Em outras palavras, o algoritmo do filtro de Kalman é recursivo e pode ser implementado basicamente com 5 equações divididas em 2 fases: a estimativa *a priori* e a atualização da estimativa (*a posteriori*). Em termos gerais, a primeira estimativa leva em conta apenas o modelo do processo enquanto a fase de atualização considera a medição.

A estimativa *a priori* é composta pelas equações abaixo, sendo que o sobrescrito x^- sinaliza um valor *a priori*. Nesta fase é feita a estimativa dos estados do sistema e o cálculo do valor *a priori* de P (matriz de covariância dos erros da estimativa), baseado em Q (matriz de covariância dos ruídos do processo w). Além disso, v representa o ruído presente na medição da saída y .

$$\hat{x}_{k+1}^- = A\hat{x}_k + Bu_k + w_k \quad (37)$$

$$\hat{y}_k = C\hat{x}_k + v_k \quad (38)$$

$$P_{k+1}^- = AP_kA^T + Q \quad (39)$$

A fase de atualização é composta pelas equações abaixo, em que o ganho de Kalman (K) é calculado a partir dos valores de R (matriz de covariância dos ruídos da medição v), P^- e C . Além disso, ocorre a atualização (calculados os valores *a posteriori*) das estimativas dos estados \hat{x}_{k+1} e a matriz de covariância P .

$$K_{k+1} = P_{k+1}^- C^T (C P_{k+1}^- C^T + R)^{-1} \quad (40)$$

$$\hat{x}_{k+1} = \hat{x}_{k+1}^- + K_{k+1}(y_k - C\hat{x}_{k+1}^-) \quad (41)$$

$$P_{k+1} = (I - K_{k+1}C)P_{k+1}^- \quad (42)$$

4.3.1 Representação do modelo em espaço de estados

O modelo que representa a dinâmica da concentração de partículas em salas limpas utilizado nesse trabalho está representado pelas Equações 27, 28 e 29. Esse modelo por ser representado de forma equivalente por uma equação diferencial linear, representado pelas Equações 43, 44 e 45.

$$\frac{dC_s}{dt} = -\alpha C_s + \beta C_o \quad (43)$$

$$[\varepsilon_v - \varepsilon_v r(1 - \eta_r)]n = \alpha \quad (44)$$

$$\left[(1 - r)(1 - \eta_n) + \frac{(G_p n_p G_m n_m - D)}{C_o n} \right] n = \beta \quad (45)$$

Como se trata de um sistema linear, utilizou-se o filtro de Kalman clássico, cujo algoritmo de implementação foi citado na seção anterior. Caso o modelo fosse não-linear, de acordo com Apio (2020), haveria a necessidade de se utilizar uma das versões do filtro de Kalman estendidas ou não-lineares que linearizam todas as transformações não-lineares em transformações lineares, como o EKF, CEKF ou MHE.

O modelo deve ser representado em espaço de estados para que possa ser utilizado o filtro de Kalman. Portanto, precisa estar representado da seguinte forma:

$$\dot{\mathbf{x}} = \mathbf{Ax} + \mathbf{Bu} \quad (46)$$

$$\mathbf{y} = \mathbf{Cx} + \mathbf{Du} \quad (47)$$

Primeiramente define-se quais serão as variáveis de estado do sistema:

$$x_1 = C_s \quad (48)$$

$$x_2 = C_o \quad (49)$$

Assumindo que a concentração de partículas no ar externo (C_o) varia muito lentamente, praticamente uma constante, então sua derivada pode ser considerada igual a zero ($\dot{C}_o = 0$). Isto posto, as derivadas das variáveis de estados são:

$$\dot{x}_1 = -\alpha x_1 + \beta x_2 + u \quad (50)$$

$$\dot{x}_2 = 0 \quad (51)$$

Após definem-se as entradas e saídas do sistema. A entrada do sistema corresponde à geração de partículas na sala, que varia conforme os cenários de utilização da sala limpa:

$$u = G_p n_p G_m n_m - D \quad (52)$$

$$y = C_o \quad (53)$$

4.3.2 Implementação do filtro de Kalman em MATLAB

A partir do sistema representado em espaço de estados, a implementação do filtro de Kalman demanda algumas etapas adicionais, como a aplicação da discretização de Euler para a obtenção da matriz de transição A , a definição do tamanho das matrizes de covariância dos ruídos (Q e R) e dos valores iniciais dos estados, da saída e das matrizes Q e R .

Aplicando a discretização de Euler no sistema (Equações 50 e 51) com um período de amostragem T e incluindo um distúrbio representado por um ruído branco $w_i(k)$, resulta nas seguintes equações de diferenças:

$$x_1(k+1) = x_1(k) - T\alpha x_1(t) + T\beta x_2(t) + w_1(k) \quad (54)$$

$$x_2(k+1) = x_2(k) + w_2(k) \quad (55)$$

Sendo w_1 e w_2 ruídos gaussianos brancos presentes no processo com variâncias Q_1 e Q_2 , respectivamente. Portanto, a autocovariância de w consiste em:

$$Q = \begin{bmatrix} Q_{11} & 0 \\ 0 & Q_{22} \end{bmatrix} \quad (56)$$

Como valores iniciais $Q_{11} = Q_{22} = 1$, podendo ser ajustado posteriormente, de acordo com o impacto do ruído de processo na estimação do estado. Assumindo que o estado x_2 é a saída do sistema (concentração de partículas no ar externo C_o), que é mensurada, insere-se o ruído de medição v ao espaço de estados:

$$y(k) = x_2(k) + v(k) \quad (57)$$

Como o sistema apresenta apenas uma saída, a variância do ruído de medição v consiste no parâmetro unidimensional R . Inicialmente, definiu-se $R = 1$. O tempo de amostragem utilizado foi $T = 0,1$ s.

Considerando que as simulações com filtro de Kalman foram realizadas com o modelo aplicado em um caso de estudo, sendo uma das salas limpas do instituto itt Chip da Unisinos, os valores iniciais dos estados estimados foram escolhidos com base no conhecimento prévio do processo: $x_1(0) = C_{SO} = 6,14 \times 10^4$, sendo o valor da concentração de partículas na sala quando esta encontra-se em repouso; $x_2(0) = y(0) = C_o = 1,08 \times 10^7$, sendo o valor médio de concentração de partículas no ar externo. Nas simulações, foi inserido um ruído branco gaussiano, representando o ruído de medição, somado ao valor médio de C_o citado acima.

Conforme Haugen (2008), a matriz de transição A , utilizada para calcular a matriz de covariância (P) e o ganho de Kalman (K), pode ser definida através do Jacobiano de $x_i(k + 1)$:

$$A = \left. \frac{\partial x_i(k + 1)}{\partial x} \right|_{x_0, u_0} \quad (58)$$

$$A = \left. \begin{bmatrix} \frac{\partial f_1}{\partial x_1} & \frac{\partial f_1}{\partial x_2} \\ \frac{\partial f_2}{\partial x_1} & \frac{\partial f_2}{\partial x_2} \end{bmatrix} \right|_{x_0, u_0} \quad (59)$$

$$A = \begin{bmatrix} (1 - T\alpha) & T\beta \\ 0 & 1 \end{bmatrix} \quad (60)$$

Com o objetivo de verificar o funcionamento do sensor por *software* com o filtro de Kalman, simulações foram executadas com um script desenvolvido em Matlab® R2018a. Como estudo de caso, utilizou-se a mesma sala limpa da seção anterior. Portanto, os mesmos parâmetros do modelo foram utilizados nessa análise.

A Figura 34 apresenta uma das simulações executadas, comparando os valores estimados pelo filtro de Kalman (em vermelho), em que foi aplicado o ruído de medição em C_o com os valores obtidos pelo modelo (em azul) sem ruído de medição em C_o . Na simulação ocorrem 4 cenários ao longo de um período de 4 horas (adicionou-se um ruído randômico para que a simulação esteja próxima à realidade), com variação do número de máquinas ligadas (n_m) e de pessoas na sala (n_p) a cada hora, conforme abaixo:

- Cenário 1: $n_p = 0$ e $n_m = 4$
- Cenário 2: $n_p = 2$ e $n_m = 6$
- Cenário 3: $n_p = 2$ e $n_m = 1$
- Cenário 4: $n_p = 1$ e $n_m = 5$

Os parâmetros Q e R são denominados de parâmetros de sintonia do filtro de Kalman. Ajustes foram feitos nesses parâmetros para diminuir o ruído do estado estimado. Reduziu-se o valor de R para 0,01 para que a magnitude do ruído presente na medida tenha menor impacto no estado estimado. Observa-se que mesmo com ruídos gaussianos em C_o , n_m , n_p e D , trata-se de uma estimativa com precisão.

A estimativa foi avaliada utilizando os critérios comumente utilizados na literatura para avaliação de observadores de estado, como o filtro de Kalman: Média Quadrática do Erro Normalizada (*NMSE-Normalized Mean Squared Error*) e Raiz Média Quadrática do Erro Normalizada (*NRMSE-Normalized Root Mean Square Error*), conforme equações abaixo:


$$NMSE = \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2 / n}{y\hat{y}} \quad (61)$$

$$NRMSE = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2 / n}{y\hat{y}}} \quad (62)$$

Os critérios foram calculados conforme as equações acima, tendo as estimativas as seguintes avaliações: $NMSE = 0,013$ e $NRMSE = 0,114$. Pode-se

observar tanto na Figura 34 como nos valores dos critérios calculados que a estimação da concentração de partículas no interior da sala mostrou-se satisfatória.

Figura 34 – Resultado do sensor por *software* com filtro de Kalman para 4 cenários diferentes



Fonte: Elaborado pelo autor.

Para uma implementação prática desse sensor por *software* na sala limpa desse estudo de caso, pode ser utilizado para medição em tempo real da concentração de partículas do ar externo (C_o) um contador de partículas óptico de baixo custo, como Alphasense OPCR1 ou Lighthouse Remote 5012 (Figura 35), sendo este último com saída analógica padrão industrial 4-20 mA.

Figura 35 – Contador de partículas óptico Lighthouse Remote 5012



Fonte: Manual do produto Lighthouse Remote 5012.

5 RESULTADOS GERAIS

A partir dos estudos e análises do processo de redução da contaminação do ar em salas limpas e do modelo simplificado de estimação de concentração de partículas, elaborou-se uma proposta de melhoria da eficiência energética do sistema HVAC do Instituto Itt Chip da UNISINOS e avaliação das consequências que as alterações propostas produzem no sistema HVAC e na qualidade do ar das salas limpas.

O insuflamento de ar ultra limpo em salas limpas sob demanda (DCF – *Demand-Controlled Filtration*) trata-se de um conceito introduzido na última década na literatura, *e.g.*, Loomans *et al.* (2019) e Molenaar (2017), como uma forma eficaz de redução do consumo de energia do HVAC, mais especificamente da etapa de insuflamento.

Esses artigos analisam dois métodos de insuflamento sob demanda, sendo que o primeiro consiste em fixar um ou mais contadores de partículas na sala limpa para monitorar em tempo real a qualidade do ar, também chamado de *fine-tuning*. A concentração de partículas na sala limpa recomenda ao operador uma redução ou aumento da taxa de trocas de ar por hora. A desvantagem deste método consiste no alto custo de aquisição e manutenção de contadores de partículas de alta precisão operando continuamente, devido à vida útil do laser e à calibração do equipamento.

Comercialmente, a única opção encontrada no mercado para melhoria da eficiência energética de salas limpas, baseado em DCF, consiste no ICCS – *Intelligent Cleanroom Control System*, criado e patenteado pela empresa britânica ECCO2, em que um contador de partículas óptico de alta precisão monitora continuamente a qualidade do ar e modula a velocidade do insuflador.

O segundo método consiste em controlar a taxa de trocas por hora em função apenas da ocupação da sala. Sensores monitoram em tempo real a quantidade de pessoas para modular a taxa de trocas de ar por hora. A desvantagem dessa técnica consiste em não levar em consideração a contaminação gerada pelas máquinas e processo, pois estes podem contaminar o ar com uma taxa maior do que as das pessoas.

A concentração de partículas estimada pelo sensor por *software* pode ser considerada um terceiro método de controle de insuflamento por demanda, pois também pode ser utilizada pelo operador da sala limpa para diminuir ou aumentar a

taxa de trocas por hora (n) do sistema HVAC da sala limpa, de acordo com a utilização da sala limpa – número de pessoas e de máquinas. Um ajuste pode ser realizado no *setpoint* do volume de ar insuflado de modo que a concentração de partículas esteja sempre dentro dos limites determinados pela norma NBR ISO 14644-1 (Tabela 2), porém com uma taxa de trocas de ar por hora (n) mínima para que isso seja possível, aliando qualidade do ar com eficiência energética do sistema HVAC da sala limpa. Os valores se tratam apenas de uma estimativa, mas como apresentaram resultados satisfatórios, mesmo se tratando de um modelo simplificado, implica-se que este possa ser utilizado, com a vantagem de possuir um baixo custo.

Convém salientar que nenhum dos métodos citados extingue a necessidade das demonstrações de conformidade da classificação da sala limpa, de acordo com a norma NBR ISO 14644-2, em que precisam ser executadas obrigatoriamente diversas medidas com um contador óptico de partículas devidamente calibrado, em diversos pontos da sala, em períodos de 6 ou 12 meses, dependendo da classificação, para que a sala limpa mantenha a sua certificação.

A Tabela 14 apresenta a taxa de trocas de ar por hora (n) em que a sala limpa do estudo de caso, Classe 8, no instituto itt Chip da Unisinos, pode operar em cada cenário de utilização, dentro dos limites definidos em norma. Observa-se que uma alternativa possível de operação do sistema HVAC consiste em reduzir o número de trocas, do valor fixo $n = 8$ para $n = 5$, quando a sala estiver em repouso ou com pouca ocupação e/ou utilização. Nesses casos, é possível reduzir a velocidade do insuflador em 37,5%. A redução no consumo de energia do insuflador pode ser calculada pela Lei da Afinidade (Equação 6), resultando em uma redução no consumo de 75,6%.


Observa-se na Tabela 14 que apenas com uma grande ocupação da sala limpa (2 pessoas e 6 máquinas) se justifica uma taxa de trocas de ar por hora igual a 8. Em todos os outros cenários é possível uma redução na referida taxa e, conseqüentemente, na velocidade e consumo de energia do insuflador do sistema HVAC. Na Figura 36 observa-se a possibilidade de redução do consumo de energia elétrica do insuflador em cada cenário, sendo que 100% representa seu consumo atual.

Tabela 14 – Taxa de trocas de ar mínima para cada cenário de utilização da sala mantendo a concentração de partículas máxima permitida em norma

Cenário	n_m	n_p	Taxa de trocas de ar por hora (n) mínimo	Redução no consumo de energia do insuflador (%)
1	1	0	5	75,6
2	2	0	5	75,6
3	3	0	5	75,6
4	4	0	6	57,8
5	5	0	6	57,8
6	6	0	6	57,8
7	0	1	5	75,6
8	1	1	5	75,6
9	2	1	5	75,6
10	3	1	6	57,8
11	4	1	6	57,8
12	5	1	6	57,8
13	6	1	7	33
14	0	2	5	75,6
15	1	2	5	75,6
16	2	2	6	57,8
17	3	2	6	57,8
18	4	2	6	57,8
19	5	2	7	33
20	6	2	8	0

Fonte: Elaborado pelo autor.

Figura 36 – Proposta de redução de trocas de ar por hora e seu impacto no consumo de energia do insuflador



Fonte: Elaborado pelo autor.

5.1 REDUÇÃO DA TAXA DE TROCAS POR HORA

Reduzir taxa de trocas de ar por hora (n) significa uma menor vazão de ar climatizado e filtrado na sala limpa. Uma baixa vazão de ar pode ter como consequências:

- 1) Dificuldade no controle das condições termais do ar dentro da sala, como umidade e temperatura, que são controladas pelas serpentinas de água fria e quente do sistema HVAC. Um volume menor de ar circulando pelas serpentinas produz uma menor troca de calor. Existe a possibilidade de este fato impactar no controle ótimo do sistema HVAC do itt Chip, que visa uma troca de calor que apresente a melhor eficiência energética possível, através de controle preditivo, abordado em Santos (2019).
- 2) Dificuldade no controle da sobrepressão, necessária para diminuir o risco de partículas adentrarem na sala limpa pelas portas e frestas. A pressão positiva dentro da sala é uma consequência dos insufladores e proporcional às suas velocidades. Uma pressão positiva mínima é necessária. Portanto, a redução da velocidade do insuflador precisa ser observada com atenção, para não comprometer a sobrepressão. O sistema HVAC da sala limpa do itt Chip permite uma taxa de trocas de ar por hora mínima de 5. Uma análise precisa ser feita para verificar se essa redução não implicará em uma queda da pressão positiva a um valor menor que o recomendado. Loomans *et al.*, (2020) afirma que esse é um fator importante a ser considerado, recomendando que o sistema de controle do HVAC considere uma restrição de pressão positiva mínima, mesmo que a sala apresente uma baixa concentração de partículas.
- 3) Queda nos níveis de oxigênio (O_2) e aumento de dióxido de carbono (CO_2): Conforme o ser humano respira dentro de um ambiente fechado e sem renovação de ar, existe a tendência de um aumento na concentração de dióxido de carbono (CO_2), gás nocivo ao ser humano, que provoca queda no rendimento, dor de cabeça, tontura e em casos extremos até a morte, de acordo com sua concentração no ar.

5.2 REDUÇÃO DO PERCENTUAL DE RENOVAÇÃO DE AR

Nas simulações e comparações com as medidas o parâmetro r (razão entre o ar recirculante o ar externo) esteve fixado em 0,9. Isso representa uma abertura de 90% no *damper* da tubulação de retorno e 10% de abertura no *damper* da tubulação do ar externo, representando que está sendo renovado 10% de todo o volume de ar da sala constantemente. Esses atuadores são complementares. Caso um *damper* opere com um percentual de abertura x , o outro opera com um percentual y , sendo que obrigatoriamente $x + y = 100$.

Caso o sistema HVAC opere com $r = 1$, ou seja, o *damper* que controla a entrada do ar externo permanece totalmente fechado, não permitindo renovação do ar, 100% do volume do ar da sala é continuamente recirculado. Analisando apenas a qualidade do ar dentro da sala limpa, essa configuração auxilia na remoção das partículas por diluição, pois o ar ultra limpo insuflado na sala limpa passa a ter uma menor concentração de partículas, uma vez que o ar externo, que possui uma alta concentração de partículas não é inserido ao processo.

Apenas para ilustrar, ao simular o modelo com $r = 1$, a concentração de partículas estimada com a sala em repouso é de $5,2 \times 10^4$ partículas/m³. Uma redução de 15% em relação a $r = 0,9$, que implica em $6,14 \times 10^4$ partículas/m³.

Porém, como já mencionado na seção anterior, um menor volume de ar renovado inserido na sala implica em nocivos riscos para as pessoas que estão dentro da sala limpa. O sistema de controle do HVAC possui uma restrição que impede que o *damper* da tubulação do ar externo feche completamente. A norma brasileira que determina o volume mínimo de renovação de ar que um ambiente fechado deve possuir em função do volume e número de pessoas é a NBR 16401.


5.3 EFICIÊNCIA DOS FILTROS

Ao longo do tempo, uma barreira de partículas começa a se formar nas faces dos filtros. Isso implica em uma queda na pressão positiva na sala limpa. Quando isso ocorre, para manter a pressão positiva em um valor mínimo desejável o sistema de controle do HVAC, ao detectar essa queda de pressão através de um sensor de pressão na tubulação, aumenta a velocidade do insuflador, gerando um desperdício de energia que pode ser evitado com uma limpeza periódica de todos os filtros do

sistema HVAC, tanto os filtros do tipo grosso, médio, fino e ultrafino. A Figura 37 apresenta o comportamento da queda de pressão na sala limpa em função do tempo e como a limpeza do filtro proporciona que este retorne praticamente às suas características originais. Em ASHRAE (2016), existem recomendações acerca dos testes de filtros, métodos e periodicidade de limpeza e tempo de vida útil para cada tipo e classe de filtros.

Além disso, também recomenda testes para verificar se não há pequenos defeitos nos filtros, onde possam atravessar partículas, o que acaba sendo mais prejudicial do que o caso anterior, pois a sala passa a ter um acréscimo indesejado de partículas que o filtro deveria estar barrando. Nesse caso, também existe a possibilidade de o sistema HVAC aumentar a velocidade do insuflador para diminuir a concentração de partículas na sala, sem obter sucesso e apenas desperdiçar energia.

Figura 37 – Queda da pressão na sala limpa em função do tempo devido ao acúmulo de partículas nos filtros



- A: Formação inicial dos depósitos de partículas após instalação de novo filtro
- B: Depósitos de partículas ocorrem de forma linear no período
- C: Formação dos depósitos de partículas após limpeza do filtro

Fonte: Adaptado de Ashrae (2016).

5.4 DEMAIS PARÂMETROS DO MODELO

Outros parâmetros do modelo de estimação de concentração de partículas podem ter seus efeitos analisados quanto à resposta estimada. O fator de eficiência de ventilação ε_v para salas limpas com regime de escoamento turbulento, possui valor médio de 0,7 conforme Zhou (2017).

De acordo com Molenaar (2017), para salas com regime de escoamento laminar, o valor de ε_v pode chegar a 9,4. Ele é determinado como:

$$\varepsilon_v = \frac{C_{exit} - C_s}{C_m - C_s} \quad (64)$$

Onde:

C_{exit} = Concentração de partículas na saída da sala para a tubulação de retorno (partículas/m³)

C_s = Concentração de partículas na entrada da sala (partículas/m³)

C_m = Concentração de partículas média na sala (partículas/m³)

Para salas com regime de escoamento laminar, esse valor precisa ser determinado experimentalmente. É dependente da localização da fonte geradora e das localizações das entradas e saídas de ar da sala. Quanto mais alto o valor desse fator de eficiência de ventilação, melhor será a qualidade do ar na sala. Utilizando o modelo, simulou-se uma estimativa de concentração de partículas para a sala em repouso, com valor de $\varepsilon_v = 4$. A estimativa resultante obtida foi de $2,84 \times 10^4$ ante $6,14 \times 10^4$, obtido com $\varepsilon_v = 0,7$.

A concentração de partículas do ar externo C_o não apresentou alterações bruscas no período em que foi monitorada, com um contador óptico de partículas de baixo custo da Alphasense, modelo OPCR1. Os valores medidos oscilaram entre $9,65 \times 10^6$ e $1,28 \times 10^7$. Simulações foram executadas e o modelo estimou que a concentração de partículas com a sala em repouso oscilou entre $5,6 \times 10^4$ e $6,3 \times 10^4$. Como uma variação da qualidade do ar externo impacta na qualidade do ar no interior da sala, recomenda-se manter um contador de partículas continuamente monitorando a qualidade do ar externo, realimentando o modelo para que o valor estimado se situe próximo ao valor real.

O valor para a taxa de deposição de partículas em superfícies (D) considerado nesse trabalho, baseou-se em Sun (2010), que conclui que valores entre 3% a 8% do total de partículas geradas na sala, no mesmo intervalo de tempo, deposita-se sobre as superfícies da sala por ação da gravidade. Após experimentos, o referido autor cita que existe uma relação inversamente proporcional entre a taxa de deposição e o número de trocas de ar por hora, *i.e.*, quanto menor a taxa de trocas de ar por hora, maior será o número de partículas que se depositam sobre as superfícies. Em Sun (2010), os experimentos variavam o número de trocas por hora entre 10 e 100.

Como a taxa de trocas por hora da sala limpa do estudo de caso é baixa ($n = 8$), utilizou-se para o parâmetro D o valor de 8% da taxa de geração de partículas gerada por uma pessoa. Portanto, $D = 1 \times 10^5$ partículas/m³h, uma média entre $5,6 \times 10^4$ e $1,44 \times 10^5$. Esse parâmetro exerce pouco impacto na estimação do modelo. Por exemplo, considerando a ocupação de uma pessoa na sala limpa ($n_p = 1$), o modelo estimou valores de concentração de partículas variando entre $1,91 \times 10^6$ e $1,99 \times 10^6$, após um tempo de 30 minutos.

6 CONSIDERAÇÕES FINAIS

Os resultados obtidos das simulações do modelo de concentração de partículas desenvolvido mostraram bom desempenho na comparação com os valores lidos pelo contador de partículas óptico, mesmo tratando-se de um modelo simplificado, baseado em uma equação diferencial linear.

Diferentes tecnologias de sensores por *software* foram abordadas neste trabalho apresentando resultados em concordância com o previsto na literatura. O erro de estimação do modelo desenvolvido encontra-se dentro da faixa aceitável do método de avaliação estatística utilizado na análise do desempenho do modelo.

O valor estimado pode ser utilizado como um método alternativo de controle de insuflamento por demanda (DCF), considerando que os métodos existentes na literatura e patenteados no mercado se baseiam, respectivamente, em sensores de presença (baixo custo e baixa precisão) e contadores de partículas ópticos (alto custo e alta precisão).

O sensor por *software* proposto caracteriza-se pelo baixo custo e uma precisão intermediária relativa aos dois métodos de DCF citados acima, pois considera não apenas o número de pessoas na sala, mas também o número de máquinas em operação, importantes fontes de geração de partículas.

Para o estudo de caso em que o sensor por *software* foi aplicado, uma das salas limpas do Instituto Itt Chip da UNISINOS, denominada Laboratório de Caracterização Física, as simulações efetuadas indicam a possibilidade de redução no consumo de energia do sistema HVAC de até 75,6%, para os cenários em que a sala limpa está em repouso ou com pouca ocupação.

O sensor por *software* desenvolvido pode ser aplicado em outras salas limpas, sendo necessária uma avaliação do impacto que as máquinas existentes na sala limpa exercem sobre a qualidade do ar, mensurando a taxa de geração de partículas de cada máquina diferente. Além dos ensaios para determinar o parâmetro supracitado (G_m), os seguintes parâmetros também são específicos para cada sala limpa e determinados através de ensaios envolvendo medidas com contador de partículas óptico: concentração de partículas inicial, com a sala em repouso (C_{SO}), fator de eficiência da ventilação (ε_v) e fatores de eficiência dos filtros.

6.1 CONTRIBUIÇÕES PARA TRABALHOS FUTUROS

A integração da concentração de partículas estimada pelo sensor por *software* pode ser futuramente aplicada ao sistema de controle do HVAC da sala limpa do estudo de caso. Para isso, precisariam ser instalados sensores infravermelhos ou outro dispositivo, como catracas, que registrem a quantidade de pessoas na sala e sensores de corrente que detectam a operação das máquinas.

Um sistema de controle preditivo foi implementado por Santos (2019) na mesma sala limpa. Segundo o autor, o controle preditivo apresenta condições de comportar uma parcela da função custo dedicada ao cumprimento desta especificação – controle da velocidade do insuflador em função da concentração de partículas na sala limpa. Para isso, será necessária a implementação de um instrumento do tipo tubo de *pitot* no duto de insuflamento, e assim acrescentar uma variável controlada: A vazão de ar insuflado. Apesar desta possibilidade de melhoria percebida no sistema, percebe-se que a infraestrutura atual do itt Chip permitiria estabelecer *targets* para as variáveis manipuladas de modo a que seja possível atingir o número de trocas desejado.

Caso a integração citada acima for implementada, um interessante estudo pode ser realizado para avaliar o impacto no controle preditivo do sistema HVAC do itt Chip, quanto à eficiência energética. Pois alterações na velocidade do insuflador levam a uma alteração na troca de calor entre as serpentinas de água fria e quente e o ar circulante. Uma troca de calor ideal é um dos objetivos do controle preditivo, realizada sempre com o mínimo possível de consumo de energia. Uma análise detalhada pode ser feita sobre quais cenários pode ser vantajoso, em termos de eficiência energética, priorizar o controle da pureza do ar ou o controle da umidade e temperatura.

O modelo de estimação de concentração de partículas pode ser melhorado com a inclusão de mais parâmetros relativos aos processos específicos da sala limpa em que for aplicado. Além da taxa de geração de partículas por pessoas e máquinas, podem ser acrescentados mais parâmetros para cada processo que ocorre na sala limpa que tem como consequência geração de partículas. Esses parâmetros (taxa de geração de partículas devido ao processo) podem ser determinados com ensaios contendo medições seguindo a mesma metodologia adotada neste trabalho para a determinação da taxa de geração de partículas de cada máquina em operação.

Um estudo detalhado pode ser feito para analisar o impacto de uma redução do insuflamento na sobrepressão, instalando um sensor de pressão na tubulação de insuflamento. Caso a pressão positiva dentro da sala limpa seja reduzida abaixo de um valor mínimo, pode ser acrescentada uma restrição ao sistema de controle, que permita a redução da velocidade do insuflador a apenas uma faixa de valores permitidos.

Outra interessante investigação consiste na quantidade de dióxido de carbono (CO_2) no interior da sala limpa. Ao instalar um sensor para monitorar a concentração de CO_2 , é possível verificar se este parâmetro de qualidade do ar está de acordo com os limites estabelecidos na norma NBR 16401, que regulamenta que valores acima de 1200 ppm proporcionam efeitos nocivos ao ser humano, tendo como efeitos mais leves reduções da eficiência no trabalho e no aprendizado. Este importante parâmetro de qualidade do ar pode também ser agregado ao sistema de controle do HVAC.

REFERÊNCIAS

- ABNT. **Norma NBR ISO 14644**. 2009.
- ACHMAD, M.; MOURSHED, M.; YUCE, B. **Computational intelligence techniques for HVAC systems: A review**. *Building Simulation*, v. 9, p. 359-398, 2016.
- ADACHI, M.; PUI, D.; LIU, B. **Development of an automatic system for measuring particle charge and size distributions in a clean room**. *Particle and Particle Systems Characterization*, v. 3, p. 200-208, 1991.
- AGUIRRE, L. A. **Introdução à Identificação de Sistemas: Técnicas lineares e não-lineares aplicadas a sistemas reais**. Belo Horizonte, Editora UFMG, 2004.
- AMAZOUZ, M.; PANTEA, R. **Use of multivariate data analysis for lumber drying process monitoration and fault detection**. *Proceedings of the International Conference on Data Mining*, p. 329-332, 2006.
- APIO, A. **Estimação de parâmetros em tempo real através de filtro de Kalman com janela robusta suavizante e estimadores de estados não-lineares**. 2020. 140 f. Tese (Doutorado em Engenharia Química) – Departamento de Engenharia Química, Universidade Federal do Rio Grande do Sul (UFRGS), Porto Alegre, 2020.
- ASHRAE. **Handbook – HVAC Systems and Equipment**. American Society of Heating, Refrigerating and Air-conditioning Engineers. 2016.
- ATKINSON, C. M.; HANZEVACK, E. **A real-time neural network-based intelligent performance and emissions prediction system**. *SAE Technical Paper 980516*, 1998.
- BAROLO, M.; BERTO, F. **Composition control in batch distillation: Binary and multicomponent mixtures**. *Industrial Engineering Chemical Research*, v. 37, p. 4689-4698, 1998.
- BOEGLI, M.; LAET, T.; SCHUTTER, J. **Moving horizon for friction state and parameter estimation**. *European Control Conference*, Zurich, 2013.
- BROWN, K. **Fundamental cleanroom concepts**. *ASHRAE Transactions* 92, v.1, 1986.
- CHEN, K.; CASTILLO, I.; YU, J.; **Softsensor model maintenance: A case study in industrial process**. *9th IFAC Symposium on Advanced Control of Chemical Process*. *Whistler*, v. 48, p. 427-432, 2015.

CHEN, S.F.; FU, W.S.; YANG, S.J. **A numerical study of effects of a moving operator on particles in a cleanroom with a curtain.** *Aerosol Science & Technology*, v. 36, n. 2, p. 154-161, 2002.

COBO, F.; CRELA, D.; CONCHA, A. **Airborne particle monitoring in clean room environments for stem cell cultures.** *Biotechnology Journal*, v. 3, n. 1, p. 43–52, 2008.

COELLO, C.; LAMONT, G.; VELDHUIZEN, D. **Evolutionary Algorithms for Solving Multi-Objective Problems (Genetic and Evolutionary Computation).** Springer-Verlag, New York, Inc. 2006.

CONZ, V. **Desenvolvimentos de analisadores virtuais aplicados a colunas de destilação industriais.** Dissertação de mestrado. Universidade Federal do Rio Grande do Sul, UFRGS, Porto Alegre, 2005.

COOPER, D. **Particulate contamination and microelectronics manufacturing: an introduction.** *Aerosol Science and Technology*, v. 5, p. 278-299, 1986.

dataPARC. **Softsensors in the process industry.** Blog da DataPARC Solutions. Disponível em: <<http://blog.dataparcsolutions.com/soft-sensors-in-the-process-industry>>. Acesso em: 10 Jan. 2019.

DAYAL, B.; MCGREGOR J. **Recursive exponentially weighted PLS and its applications to adaptative control and prediction.** *Journal of Process Control*, v. 7, n. 3, p. 169-179, 1997.

DIEHL, F. C. **Simulação operacional de uma torre de destilação e avaliação de modelos de analisadores virtuais.** *SBA Controle e Automação* v. 20, n. 3. Natal, 2009.

DIXON, K.; DOLAN, J. **A real and virtual environment for multiple mobile robot systems.** *Proceedings of the IEEE IROS'99*. Kyongju, Korea, 1999.

DONG, D.; MCAVOY, T.; CHANG, L. **Emission monitoring using multivariate softsensors.** *Proceedings on American Control Conference*, v. 1, p. 761-765, 1995.

DUNIA, R.; QIN, S.; EDGAR, T. **Identification of faulty sensors using principal component analysis.** *AIChE Journal*, v. 42, n. 10, p. 2797-2812, 1996.

ENGEL, T.; GASTEIGER, J. **Applied Chemoinformatics: Achievements and Future Opportunities.** Weinheim, Germany. Wiley, 2018.

FACCHIN, S. **Técnicas de análise multivariável aplicadas ao desenvolvimento de analisadores virtuais**. Dissertação de Mestrado, Universidade Federal do Rio Grande do Sul, 2005.

FORTUNA, L.; GRAZIANI, S.; RIZZO, A.; XIBILIA, M.G. **Softsensors for monitoring and control of industrial processes**. London. Springer-Verlag, 2007.

FORTUNA, L.; GRAZIANI, S.; XIBILIA, M.G. **Softsensors for product quality monitoring in debutanizer distillation columns**. Control Engineering Practice, v. 13, n. 4, p. 499-508, 2005

GONZALES, G. D. **Softsensors for processing plants**. 2nd International Conference on Intelligent Processing and Manufacturing of Materials, v. 1, p. 59-70. Hawaii, 1999.

GONZALES, G. D.; REDARD, J. P. **Issues in softsensor applications in industrial plants**. IEEE International Symposium on Industrial Electronics, p. 380-385. Santiago, 1994.

GONZALEZ, C. F. R.; ASCENCIO, R. R. L. **Estimación de biomasa y pigmento en línea para una fermentación tipo fed-batch utilizando redes neurales artificiales**. In: MEMORIAS DEL CONGRESO SOMI XV, Guadalajara, 2000.

GONZALEZ, M.; ESTEBAN, E.; SALGADO, O. **Methods and tools for model-based virtual sensors applied to condition monitoring**. 8th European Workshop on Structural Health Monitoring, Bilbao, 2016.

GUILANDOUST, A.; MORRIS, A. J.; THAM, M. T. **An adaptive estimation algorithm for inferential control**. Ind. Eng. Chem. And Research, v. 27, n, 9, p. 1658-1664, 1988.

HAUGEN, F. **Kompendium for Kybernetikk**. Ed. 2, Oslo, 2008.

HE, C.; MORAWSKA, L.; GILBERT, D. **Particle deposition rates in residential houses**. Atmos. Environ., v. 39, p. 3891-3899.

HU, S.; SHIUE, Y.; SHIUE, A. **Removal characteristics of particulate matter with different return air system designs in a nonunidirectional cleanroom for integrated circuit testing process**. HVAC & Research, v. 20, p. 162-166, 2014.

ICCS. **Intelligent Cleanroom Control System**. Disponível em: <<http://www.eeco2.com/iccs>>. Acesso em: 06 mai. 2020.

IEST. Institute of Environmental Sciences and Technology. **RP-CC012.1. Recommended Practices**. Disponível em: <<https://www.iest.org/Standards-RPs/Recommended-Practices/IEST-RP-CC012>>. Acesso em: 15 mai. 2020.

ISERMANN, R. **Process fault detection based on modeling and estimation methods – A survey**. Automatica Journal, v. 20, p. 387-404, 1984.

ITO, E. H. **Desenvolvimento de um sensor virtual de composição em coluna de destilação para aplicação em tempo-real**. Dissertação de mestrado. Universidade federal do Rio de Janeiro, 2014.

JAISINGHANI, R. **Energy efficient low operating cost cleanroom airflow design**. IEST ESTECH Conference, Phoenix, 2003.

JANOS, A.; BARBARA, F.; TIBOR, K. **Data-driven development and maintenance of softsensors**. IEEE 12th International Symposium on Applied Machine Intelligence and Informatics. Herl'any, 2014.

JOSEPH, B.; BROSILOW, C. B. **Inferential control of process: Part I. Steady state analysis and design**. American Institute of Chemical Engineers Journal, v. 24, p. 485-492, 1978.

JUNIOR, A. P. C. **Inferência na otimização e controle de colunas de destilação via funções racionais**. Dissertação de mestrado, Universidade Estadual de Campinas, 1996.

KADLEC, P.; GABRYS, B. **Data-driven softsensors in the process industry**. Computers & Chemical Engineering, v. 33, n. 4, p. 795-814. 2009.

KANO, M.; OGAWA, M. **The state of art in chemical process control in Japan**. Journey of process control, v. 20, n. 9, p. 969-982, 2010.

KHALIL, H. K. **Nonlinear Systems**, ed. 3, Prentice Hall, 2002.

KORDON, A. K.; SMITS, G. F.; KALOS, A. N. **Robust soft sensor development using genetic programming**. Data Handling in Science and Technology, v. 23. Elsevier, p. 69-106.,2003.

KRESTA, J. V., MARLIN, T.E., MACGREGOR, J. F., 1994. **Development of inferential process models using PLS**. Computers & Chemical Engineering, v. 18 p. 597-611, 1994.

KRIPPNER, E. **Classificação de Áreas Limpas**. Artigo Técnico. Disponível em: <<http://www.pharmaarquitetos.com/artigos/Artigo03.pdf>>. Acesso em: 20 nov. 2018.

LAN, C.H.; CHEN, J.J.; JENG, M.S. **The development of fan filter unit with flow rate feedback control in a cleanroom.** Building and Environment, v. 42, p. 3556-3561, 2007.

LEE, D.; WOO, S.; KIM, Y. **Nonlinear dynamic partial least squares modelling of a full-scale biological wastewater treatment plant.** Process Biochemistry, v. 41, n. 9, p. 2050-2057, 2006.

LEONDES, C. T.; **Mechatronic Systems Techniques and Applications: Diagnostic, Reliability and Control Systems.** Boca Raton. CRC Press, 2000.

LEVY, J. M.; OHADI, M.; CHOO, K. **Energy analysis of cleanrooms in an academic research building.** ASHRAE Transactions, v. 121. 2015.

LINHARES, L. **Redes neurais artificiais para identificação da fração molar de pentanos na composição de GLP.** VIII Simpósio Brasileiro de Automação Inteligente. 2007.

LIU, J. **On-line softsensor for polyethylene process with multiple production grades.** Control Engineering Practice, v. 15, n. 7, p. 769-778, 2007.

LOOMANS, M. G.; LUDLAGE, T. B.; OEVER, H. V.; MOLENAAR, P. C. **Experimental investigation into cleanroom contamination build-up when applying reduced ventilation and pressure hierarchy conditions as part of demand-controlled filtration.** Building and Environment, v. 176, 2020.

LOOMANS, M. G.; MOLENAAR, P. C.; KORT, H. S.; JOOSTEN, P. H. **Energy demand reduction in pharmaceutical cleanrooms through optimization in ventilation.** Energy & Buildings, v. 202, 2019.

LOTUFO, F. A.; GARCIA, C. **Sensores virtuais ou Softsensors: Uma introdução.** 7th Brazilian Conference on Dynamics, Control and Applications. Presidente Prudente, 2008.

LOTUFO, F. A. **Desenvolvimento de um sensor virtual para processos não-lineares e variantes no tempo.** Tese de Doutorado. Universidade Estadual Paulista, 2010.

MA, M.; KO, J.; WANG, S. **Development of adaptative softsensor based on statistical identification of key variables.** Control Engineering Practice, v. 17, n. 9, p.1026-1034, 2009.

MATHEW, P. A.; TSCHUDI, W.; SARTOR, D.; BEASLEY, J. **Cleanroom energy efficiency.** ASHRAE Journal: 24–32, 2010.

MERRITT, R. Hardware vs. virtual analysers. **Control Magazine**. Março, 2002. Aplicações de sensores virtuais em fabricação de papel. Disponível em: <http://www.controlmagazine.com/Web_First/ct.nsf/ArticleID/PSTR-56KM9>. Acesso em: 06 set. 2018.

MIRANDA, F. C. **Inferências para controle de uma torre de destilação atmosférica de uma refinaria**. 3º Congresso Internacional de Automação, Sistemas e Instrumentação. São Paulo, 2003.

MOLENAAR, P. C. A. **Ventilation efficiency improvement in pharmaceutical cleanrooms for energy demand reduction**. Student thesis: Master. Eindhoven University of Technology, 2017.

MORRIS, A. J.; MONTAGUE, G. A.; THAM, M. T. **Softsensors in industrial process control**. IEE Colloquium on Applied Developments in Process Control. London, 1989.

MORRISON, P. **Environmental control in electronic manufacturing**. Van Nostrand Reinhold, 1973.

MUIR, P. **A virtual sensor approach to robot kinematic identification**. Proceedings of the 1990 IEEE International Conference on Systems Engineering, p. 440-445. 1990.

MURATORI, M. **Energy consumption of residential HVAC systems: A simple physically-based model**. IEEE Power and Energy Society General Meeting, p.1-8, 2012.

MUSSI, R.; DIMURO, G.; BEDREGAL, B.; **Números Fuzzy Intervalares**, XXXII Congresso Nacional de Matemática Aplicada e Computacional, Cuiabá, 2009.

MUSTAFARAJ, G.; CHEN, J.; LOWRY, G. **Development of room temperature and relative humidity linear parametric models for an open office using BMS data**. Energy and Buildings, v. 42, n. 3, p. 348-356, 2010.

NOH, K.; KIM, H.; OH, M. **Study on contamination control in a minienvironment inside clean room for yield enhancement based on particle concentration measurement and airflow**. Building and environment, v. 45, p. 825-831, 2010.

OGUNSOLA, O. T.; WANG, J.; SONG, L. **Survey of particle production rates from process activities in pharmaceutical and biological cleanrooms**. Science and Technology for the Built Environment, v. 25, p. 692-704.

OOSTEROM, M. **Virtual sensor for fault detection and isolation in flight control systems**. Proceedings of the 39th IEEE Conference on Decision and Control. Sydney, 2000.

PARK, S.; HAN, C. **A nonlinear softsensor based on multivariate smoothing procedure for quality estimation**. Computer e Chemical Engineering, v. 24, n. 2, p. 871-877. 2000.

PARRISH, J. R.; BROSILOW, C. B. **Nonlinear inferential Control**. American Institute of Chemical Engineers Journal, v. 34, p. 633-644, 1988.

PAVILION. Pavilion Technologies. **Aplicações de soft-sensor em tratamento de água**. Disponível em: <http://www.pavtech.com/pavilion/value/industry/environmental/Environmental_Water.html>. Acesso em: 06 set. 2018.

PEREIRA, D.; FRATINI, A. **Desenvolvimento e implementação de controladores nebulosos em uma coluna de destilação**. Dissertação de Mestrado, Universidade Estadual de Campinas, 1999.

PEREIRA, M. L. **Medição, predição e análise de partículas aéreas em salas cirúrgicas**. 2008. 196 f. Tese (Doutorado em Engenharia Mecânica) – Escola Politécnica, Universidade de São Paulo (USP), São Paulo, 2008.

QUINTERO-MARMOL, E. **Applications of an entended Luenberger observer to the control of multicomponent batch distillation**. Industrial Chemical Engineering Research, v. 30, p. 1870-1880, 1991.

RAMSTORP, M. **Introduction to contamination control and cleanroom technology**. Ed. Wiley-VCH. Weinheim, 2000.

ROTATCH, V.; HADJISKI, M. **Optimal static inferential systems**. Proceedings of the Technical Cybernetics, v. 3, Academy of Sciences of the USSR, p. 199-205, 1966.

ROTEM, Y.; WACHZ, A. LEWIN, D.; **Ethylene compressor monitoring using model based PCA**. AIChE Journal, v. 46, n. 9, p. 1825-1836, 2000.

ROWEL, D. **Introduction to recursive least squares – Adaptative filters**. <http://ocw.mit.edu/courses/mechanical-engineering/2-161-signal-processing-continuu-and-discrete-fall-2008/study-materials/rls.pdf>. Acesso em: 27 nov. 2018.

SANTOS, C. F. **Controle preditivo aplicado a um sistema HVAC. Caso de estudo: Sala limpa do itt Chip Unisinos**. Dissertação de Mestrado, Unisinos, 2019.

SHARMIN, R.; SHAH, S.; SUN, Y. **Inferential sensors for estimation of polymer quality parameters: Industrial application of a PLS-based softsensor for a LDPE plant.** Chemical Engineering Science, v. 61, n. 19, p. 6372-6384, 2006.

SIEGEL, M. **Sensor Modeling and simulation.** VIMS, 2001.

SILVA, R. G. **Projeto conceitual sala limpa.** Trabalho de Conclusão de Curso. Universidade do Vale do Paraíba, 2012.

SIMON, D. **Kalman filtering with state constraints: A Survey of linear and nonlinear algorithms.** IET Control Theory & Applications, v. 4, n. 8, p. 1303-1318, 2010.

SIVAK, M. **Potential energy demand for cooling in the 50 largest metropolitan areas of the world: Implications for developing countries.** Energy Policy, v. 37, n. 4, p. 1382–1384, 2009.

SOLLE, D.; HITZMANN, B.; HERWIG, C. **Between the poles of data-driven and mechanistic modeling for process operation.** Chemie Ingenieur Technik, v.89, n.5, p.542-561, 2017.

SOUZA, F.; ARAUJO R. **Online mixture of univariate linear regression models for adaptative softsensors.** IEEE Transactions on Industrial Informatics, v. 10, n. 2, p. 937-945, 2014.

SUN, W. **Conserving fan energy in cleanrooms.** ASHRAE Journal, July, 2008.

SUN, W. **Development of Cleanroom Required Airflow Rate Model Based on Establishment of Theoretical Basis and Lab Validation.** ASHRAE Transactions, vol. 116, 2010.

SUN, Z.; ZHAO, J.; SHI, Z.; **Soft sensing of magnetic bearing system based on support vector regression and extended Kalman filter.** Mechatronics, v. 14, p. 186-197, 2014.

TIAN, H.; DENG, X. **Softsensor for polypropylene melt index based on improved orthogonal least squares.** 8th World Congress on Intelligent Control and Automation, 6 de julho de 2010, Jinan, China, p. 5881-5885, 2010.

TONEL, G. **Avaliação dos estimadores EKF, CEKF e MHE para aplicações em linha em processos.** Dissertação de Mestrado. Universidade Federal do Rio Grande do Sul, 2008.

TORREIRA, R. **Salas limpas: Instalações e manutenção.** São Paulo, Ed. Hemus, 1991.

VENTIM, F. F. **Controle robusto de uma torre estabilizadora de nafta.** Dissertação de Mestrado. Universidade Federal do Rio de Janeiro, 2010.

VENTURIM, R.; FERREIRA, L.; PEREIRA, F. **Desenvolvimento de um sensor virtual para monitoramento de índice de Wobbe.** 22º Seminário de Automação e TI. São Paulo, 2018.

VIJAYA, R.; RADHAKRISHNAN, T.; SRINIVASAN, K. **Softsensor based composition estimation and controller design for an ideal reactive distillation column.** ISA transactions, v. 50, n. 1, p. 61-70. 2011.

VUTLA, S.; PATNAIK, P.; RAMASWAMY, K.; **Effect of particle and contaminants on the static response of a rectangular MEMS diaphragm due to adverse clean room environment.** IEEE Conference on Postgraduate Research in Microelectronics and Electronics, 2013.

WANG, X.; KRUGER, U.; IRWIN, G. **Process monitoring approach using fast moving window PCA.** Industry and Engineering Chemistry Research, v. 44, n. 15, p. 5691-5702, 2005.

WEBER, R.; BROSILOW, C. **The use of secondary measurements to improve control.** American Institute of Chemical Engineers Journal, v. 18, n. 3, p. 614-623, 1972.

WEBSTER, J. G. **Measurement, instrumentation, and sensors handbook.** New York. CRC Press LLC, 1999.

WELCH, G.; BISHOP, G. **An introduction to the Kalman Filter.** University of North Carolina. Chappel Hill, 2004.

WERLE, L. O. **Analísadores virtuais baseados em modelo neural para monitoramento e controle de colunas de destilação com aquecimento distribuído.** Dissertação de Mestrado. Universidade Federal de Santa Catarina. 2012.

WOLD, S., RUHE, A., WOLD, H., DUNN, W., **The collinearity problem in linear regression: The partial least squares approach to generalized inverses.** SIAM J. Sci.Stat.Comput., v. 5, p. 753-743, 1984.

WHITE, F. M. **Mecânica dos fluidos.** São Paulo. Ed. McGraw-Hill, 2002.

XU, L.; ZHANG, W. **Comparison of different methods for variable selection.** Analytica Chimica Acta. v. 446, p. 475-481, 2001.

XU, Z. **New development of air cleaning technology.** Building Science, v. 26, n. 10, p. 34-40, 2003.

XU, Z. **Fundamentals of air cleaning technology and its application in cleanrooms**. London, Springer-Verlag, 2014.

YAN, W.; TANG, D.; LIN, Y. **A data-driven softsensor modeling method based on deep learning and its application**. IEEE Transactions on Industrial Electronics, v. 64, 2017.

ZADEH, L. A. **Fuzzy Sets**. Information and Control, v. 8, p. 338-353, 1965.

ZANATA, D. **Desenvolvimento de sensor virtual empregando redes neurais para medição de composição em uma coluna de destilação**. Dissertação de Mestrado, USP, 2005.

ZHAO, B.; WU, J.; **Numerical investigation of particle diffusion in a clean room**. Indoor and Built Environment, v. 14, p. 469-479, 2005.

ZHOU, L.; SUN, W.; HUANG, C. **Studies on comparison of particle concentration models for cleanroom**. Procedia Eng. 205, p. 3308-3315, 2017.

ZHIQIANG, G.; ZHIHUAN, S. **Ensemble independent component regression models and soft sensing application**. Chemometrics and Intelligent Laboratory Systems, v. 130, p. 115-122, 2014.