

Melhoria na eficiência energética da ventilação de salas limpas obtida por modelo de estimação de concentração de partículas

Esmael de O. Flores*. Rodrigo I. G. Mejia*
Cleiton B. da Porciúncula**

*Universidade do Vale do Rio dos Sinos – UNISINOS, São Leopoldo, Brasil
(e-mail: esmaelflores@gmail.com, rmejia@unisinis.br)

**Universidade do Estado do Rio Grande do Sul – UERGS, Santa Cruz do Sul, Brasil
(e-mail: cleiton-porciuncula@uergs.edu.br)

Abstract: There is a significant potential for energy savings in cleanroom air conditioning systems. Insufflators, which recirculate ultra-clean air, are assets that demand high energy costs. Several publications report that the amount of airflow to cleanrooms is usually projected above the required value. In parallel, several published studies propose models for estimating the concentration of particles in cleanrooms, considering several operational characteristics. In this work, the air change rate is estimated and supplied to the controlled environment as needed, generating energy savings by reducing the insufflator speed, through a softsensor composed of an estimation model of particle concentration inside a cleanroom. The main parameters of the sensor modelled by the software are corrected by non-linear optimization with restrictions. As a case study, one of the clean rooms of the 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% the energy consumed by the HVAC system fan.

Resumo: Existe um potencial significativo de economia de energia nos sistemas de climatização de salas limpas. Insufladores, os quais recirculam ar ultra-limpo, são ativos que demandam grandes custos de energia. Diversas publicações relatam que a vazão de ar para 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 taxa de trocas de ar por hora pode ser estimada e fornecida ao ambiente controlado conforme a necessidade, 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. 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.

Keywords: Softsensor; Cleanrooms; Particle concentration; Control process; HVAC system; Energy efficiency

Palavras-chaves: Sensor por software; Salas limpas; Concentração de partículas; Controle de processos; Sistema HVAC; Eficiência energética

1. INTRODUÇÃO

Diversos trabalhos podem ser encontrados na literatura, como em Matthew (2010) e Levy (2015), abordando o padrão de consumo de energia de salas limpas e mostrando que o componente com o maior impacto no custo operacional 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. Segundo Loomans *et al.* (2019), a vazão de ar na maioria das salas limpas está superdimensionada, pois seguem recomendações publicadas há mais de duas décadas, como em IEST RP-12 (1993), que associam a vazão de ar somente à classe de limpeza conforme a norma NBR ISO 14644 e não a aspectos

operacionais típicos de uma sala limpa que impactam diretamente na concentração de partículas, como taxa de geração de partículas, qualidade do ar externo e qualidade dos filtros. Além disso, os autores também citam diversas salas limpas de indústrias que operam com vazão de ar por hora – velocidade do insuflador – com potencial de redução. Os autores propõem para as indústrias uma redução da ordem de 30% na referida taxa, tendo como consequência uma redução média de 66% no consumo de energia dos insufladores.

2. QUALIDADE DO AR EM SALAS LIMPAS

A qualidade do ar em uma sala limpa é definida principalmente pela taxa de trocas de ar por hora (ACR – Air Change Rate) do sistema HVAC (*Heating, Ventilation and Air Conditioning*) de

uma sala limpa. Conforme Kircher *et al.* (2010), diversas outras variáveis também acarretam comprovada influência na qualidade do ar na sala. Essas variáveis são apresentadas na Figura 1.

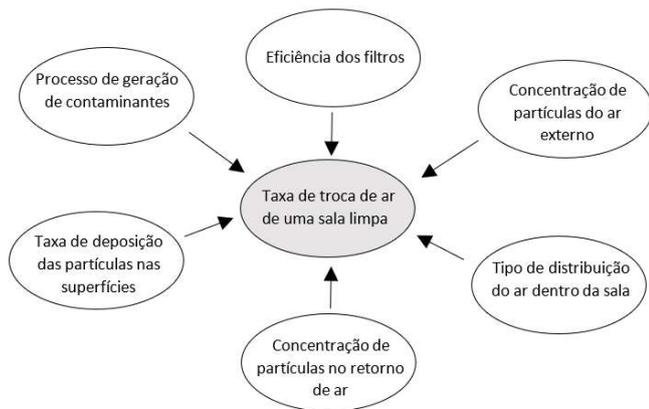


Fig. 1: Características que influenciam na taxa de trocas de ar e na qualidade do ar de uma sala limpa

Os projetistas e operadores de salas limpas costumam definir a taxa de trocas de ar por hora utilizando recomendações, como em IEST (1993), apresentada na Tabela 1.

Tabela 1: Recomendações de taxas de trocas de ar por hora em função da classificação da sala limpa conforme NBR ISO 14644

Classe	Trocas/h	Veloc. Ar (m/s)
3	360-540	0,5-0,6
4	300-540	0,4-0,5
5	240-480	0,3-0,5
6	150-240	0,2-0,4
7	60-90	0,2-0,3
8	5-48	0,1-0,2

Observa-se que tais recomendações 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 demais presentes na Figura 1. Altas taxas de trocas de ar por hora implicam em alto consumo de energia, pois tornam-se necessários grandes diâmetros e velocidades de ventiladores para recircular o ar, visto que o ar no interior da sala é limpo através da diluição, em salas com escoamento turbulento de ar.

Tabela 2: NBR ISO 14644 – Classificação de salas limpas

Classe	Número máximo de partículas por m ³ de ar				
	≥ 0,1 μm	≥ 0,3 μm	≥ 0,5 μm	≥ 1 μm	≥ 5 μm
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

A classificação de uma sala limpa se dá através da norma NBR ISO 14644, conforme Tabela 2. Uma sala limpa classe 8, por exemplo, pode conter uma concentração de partículas de, no máximo, 3.520.000 partículas/m³, sendo que as partículas podem ter diâmetros superiores a 0,5 μm.

3. MODELOS DE ESTIMAÇÃO DE CONCENTRAÇÃO DE PARTÍCULAS

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, de acordo com sua classe de limpeza. Uma das alternativas mais eficientes consiste em acompanhar em tempo real a concentração de partículas no interior da sala limpa com um contador de partículas óptico e modular a velocidade do insuflador do sistema HVAC de acordo com a necessidade. Conforme Loomans *et al.* (2019), esse conceito denomina-se filtragem controlada por demanda, do inglês *Demand-Controlled Filtration* (DCF). Este conceito pode ser aplicado através de 2 métodos:

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. 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.

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 comparado às pessoas.

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 do que as recomendações apresentadas na Tabela 1. O resultado da estimativa 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, vide Tabela 2. Portanto, um modelo de estimativa de concentração de partículas pode ser considerado também um método alternativo de DCF, pois além de considerar a ocupação da sala, também considera o número de máquinas ligadas como parâmetros de entrada do modelo de estimativa.

Baseando-se no conceito de balanço de massa e nas hipóteses que a concentração de contaminantes seja uniforme no ambiente e de que exista uma mistura homogênea do ar, diversos modelos que relacionam concentração de partículas

com taxa de trocas de ar por hora foram publicados na literatura, como Xu (2003).

Conforme Sun (2010), os modelos baseiam-se no princípio básico de funcionamento de uma sala limpa com 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. Uma relação matemática pode ser então estabelecida, 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) e Jaisinghani (2001). Nos últimos anos, houve uma evolução nos modelos, tornando-os mais descritivos, uma vez que foram adicionadas outras variáveis significativas do processo, como os modelos definidos em Xu (2003), Sun (2010) e Zhou (2017).

3.1 Modelo proposto em Zhou (2017)

O modelo de concentração de partículas proposto por Zhou (2017) trata-se do modelo mais completo encontrado atualmente na literatura, pois possui o número de parâmetros, incorporando-os de Sun (2010) e Xu (2003). Modelos baseados nos conceitos de balanço de massa são simplificados, principalmente por assumirem que a distribuição das partículas no ar dentro da sala limpa é uniforme. São representados por equações diferenciais lineares de 1º grau.

A partir das definições acima e dos parâmetros encontrados na Figura 2, conforme Zhou (2017), realiza-se a modelagem matemática de concentração de partículas em salas limpas.

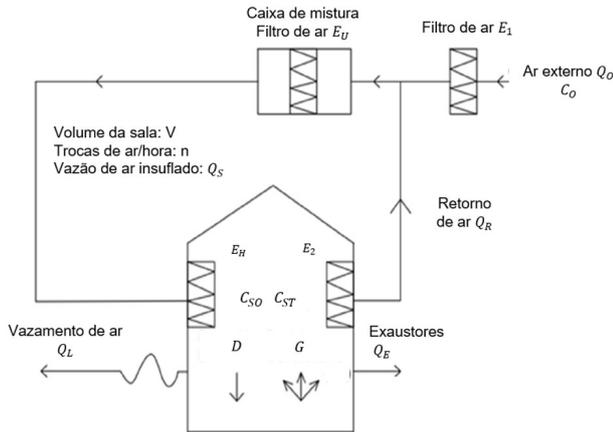


Fig. 2: Configuração básica do escoamento de ar em salas limpas

Onde:

- V = Volume da sala (m^3)
- Q_o = Vazão volumétrica de ar externo (m^3/h)
- Q_s = Vazão volumétrica de ar insuflado na sala (m^3/h)
- Q_R = Vazão volumétrica de ar de retorno (m^3/h)
- Q_E = Vazão volumétrica de ar nos exaustores (m^3/h)
- Q_L = Vazão volumétrica 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 (razão entre a concentração de partículas na sala e no retorno de ar)
- G = Taxa de geração de partículas (partículas/ m^3 hora)
- D = Taxa de deposição de partículas (partículas/ m^3 hora)
- r = Razão entre o ar de retorno e o externo
- t = Tempo (h)
- n = Taxa de trocas de ar por hora

A Equação (1) de balanço de massa das partículas no interior da sala pode ser estabelecida como:

$$V \frac{dC_s}{dt} = a + b - c - d \quad (1)$$

Onde:

- a = concentração de partículas que entram na sala
- b = concentração de partículas gerada internamente
- c = concentração de partículas que saem da sala
- d = concentração de partículas removidas por deposição

A Equação (1) pode ser descrita, analisando a Figura 2, conforme expresso na Equação (2):

$$V \frac{dC_s}{dt} = Q_o C_o (1 - \eta_n) + Q_R \epsilon_v C_s (1 - \eta_r) + GV - [Q_R C_s + Q_E \epsilon_v C_s + Q_L \epsilon_v C_s + DV] \quad (2)$$

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, após manipulações algébricas - que podem ser vistas em detalhes em Zhou (2017) - obtém-se a Equação (3), que consiste no modelo matemático capaz de estimar a concentração de partículas em uma sala limpa, onde os termos α e β são descritos em (4) e (5).

$$C_{ST} = \left(C_{SO} - \left(\frac{\beta}{\alpha} \right) C_o \right) e^{-\alpha t} + \left(\frac{\beta}{\alpha} \right) C_o \quad (3)$$

$$\alpha = \epsilon_v - \epsilon_v r (1 - \eta_r) \quad (4)$$

$$\beta = (1 - r)(1 - \eta_n) + \frac{(G - D)}{C_o n} \quad (5)$$

3.2 Parâmetros acrescentados ao modelo de Zhou

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 (2017), onde foram acrescentadas algumas variáveis referentes à geração de partículas no interior da sala limpa.

A geração de partículas na sala limpa é representada em (5) pelo parâmetro G . Verificou-se que esse parâmetro pode ser

desmembrado em outros quatro parâmetros, melhorando a precisão do modelo, sendo:

G_p = Taxa de geração de partículas gerada por uma pessoa (partículas/m³·h)

G_m = Taxa de geração de partículas gerada por uma máquina (partículas/m³·h)

n_p = Número de pessoas na sala

n_m = Número de máquinas na sala

Dessa forma, o modelo passa a ser o seguinte, descrito em (6), tendo os parâmetros α e β descritos em (7) e (8).

$$C_{ST} = \left(C_{SO} - \left(\frac{\beta}{\alpha} \right) C_o \right) e^{-\alpha n} + \left(\frac{\beta}{\alpha} \right) C_o \quad (6)$$

$$\alpha = n[\varepsilon_v - \varepsilon_v r(1 - \eta_r)] \quad (7)$$

$$\beta = n \left[(1 - r)(1 - \eta_n) + \frac{(G_p n_p G_m n_m^{-D})}{C_o n} \right] \quad (8)$$

4. APLICAÇÃO DO MODELO EM UMA SALA LIMPA

Para verificar o funcionamento do modelo de estimação de concentração de partículas, este foi aplicado em uma das salas limpas pertencentes ao instituto itt-Chip, localizado dentro do campus da UNISINOS em São Leopoldo-RS. A sala limpa utilizada é classificada como ISO-8 e possui as seguintes dimensões: 11 x 4,8 x 2,9 m. Seu sistema HVAC possui um insuflador capaz de fornecer ar ultra limpo à sala a uma taxa de trocas de ar por hora (ACR) situada entre 5 e 20. Uma consulta ao sistema de controle do HVAC permitiu verificar que o *setpoint* do sistema está fixado em 8 trocas de hora, permanentemente, estando a sala em repouso ou em uso.

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), $E_U = 0,75$ (Filtro tipo Fino Classe F8), $E_H = 0,9995$ (Filtro tipo HEPA Classe H13), $\varepsilon_v = 0,7$ (Escoamento turbulento).

Os demais parâmetros do modelo, como C_o , D , G_p , e G_m necessitaram de estudos do comportamento das partículas em diversas medições da concentração de partículas com um instrumento denominado contador de partículas óptico, sendo utilizado o modelo P611 da marca Airys (Figura 3), sendo que foram consideradas em todas as medições as partículas de diâmetros entre 0,5 μ m e 5 μ m.



Fig. 3: Contador de partículas óptico utilizado nas medições

A média de dez medidas da qualidade do ar externo realizadas em cinco dias diferentes resultou em $C_o = 1,08 \times 10^7$ partículas/m³, com desvio padrão da média de $2,2 \times 10^5$ partículas/m³. A taxa média de geração de partículas na sala por uma pessoa (G_p), foi obtida através de uma média de 20 medidas com o contador de partículas na sala limpa, divididos em quatro grupos. Cada grupo de medidas representando um cenário diferente, variando de uma pessoa na sala sentada movimentando apenas os braços até uma pessoa caminhando em ritmo acelerado. Por fim, obtendo-se o valor $G_p = 1,249 \times 10^6$ partículas/m³·h, com desvio padrão da média de $2,4 \times 10^5$ partículas/m³·h. A taxa de deposição (D) pode ser considerada, conforme Sun (2010), como 8% da taxa de geração de partículas geradas na sala limpa. Portanto, $D = 1 \times 10^5$ partículas/m³·h.

Para se obter o parâmetro G_m , que consiste na taxa média de geração de partículas 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 um sistema com 6 ventiladores de 12 cm de diâmetro, instalados no chão, direcionados para o centro da sala, capazes de movimentar as partículas e assim serem agentes geradores de partículas suspensas no ar, desse modo abstraindo as máquinas, como por exemplo de solda, no caso de uma indústria de semicondutores. A Figura 4 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) na qualidade do ar na sala.



Fig. 4: Ambiente controlado montado na sala limpa

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. O microcontrolador acoplado a uma placa de relés para acionamento dos ventiladores pode ser observado na Figura 5.

Um total de 12 ensaios foram feitos nesse ambiente controlado para se chegar ao seguinte valor médio da taxa de geração de partículas por uma máquina: $G_m = 1,511 \times 10^6$ partículas/m³·h, com desvio padrão da média de $2,4 \times 10^5$ partículas/m³·h,

utilizando configurações e sequências diferentes de acionamento dos seis ventiladores presentes na sala limpa conforme Tabela 3.

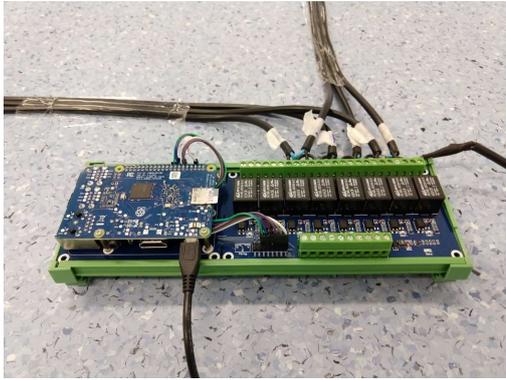


Fig. 5: Microcontrolador Rapsberry Pi utilizado para acionar os ventiladores no ambiente controlado

Tabela 3: Ensaios realizados para encontrar o 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

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, efetuou-se a medição da concentração de partículas suspensas no ar cinco vezes, em dias diferentes, cuja média resultou em $C_{SO} = 6,14 \times 10^4$ partículas/ m^3 , com desvio padrão da média de $8,6 \times 10^2$ partículas/ m^3 .

Tendo todos os parâmetros do modelo, foi possível desenvolver um script em Matlab® R2018a para simular seu desempenho. Executou-se uma simulação do modelo, apresentada na Figura 6, para estimar a concentração de partículas na sala limpa ao longo de um intervalo de uma hora, em que quatro cenários diferentes de utilização da sala limpa acontecem, variando o número de pessoas (n_p) e de máquina ligadas (n_m).

Observa-se na Figura 6 que a concentração de partículas suspensas no ar é maior conforme o aumento da quantidade de pessoas presentes na sala e da quantidade de máquinas ligadas.

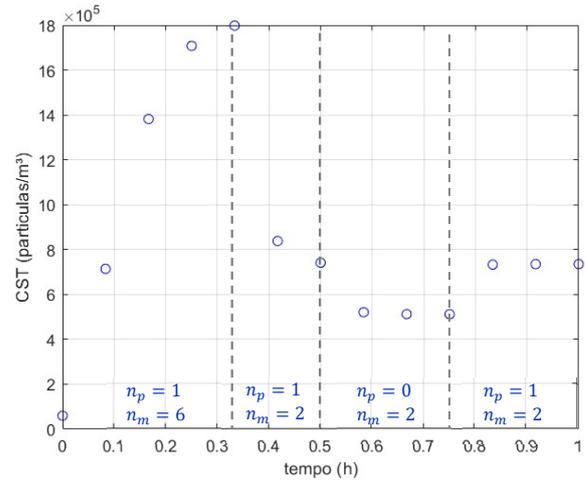


Fig. 6: Simulação realizada com o modelo de estimação de concentração de partículas com 4 cenários diferentes.

4.1 Validação do modelo de estimação

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 ótico em cada instante de tempo, desde o repouso em $t = 0$ até $t = 30$ minutos, repetindo-se a cada período de 5 minutos nesse intervalo. A mesma metodologia foi replicada para todos os cenários. Essa passa a ser a base de dados de medições da sala limpa desse estudo de caso e será utilizada na próxima seção desse artigo (Correção do modelo). A Tabela 4 apresenta parcialmente, apenas para $t = 5$ min e $t = 30$ min, os resultados das médias das cinco medições de cada um dos vinte cenários no ambiente controlado (C_r) e o resultado da estimação do modelo (C_e).

Tabela 4: Tabela comparativa entre as medições realizadas em vinte cenários e o resultado da estimação do modelo

Cenário	n_m	n_p	5 min		30 min	
			C_r ($\times 10^5$)	C_e ($\times 10^5$)	C_r ($\times 10^5$)	C_e ($\times 10^5$)
1	1	0	1,233	1,279	2,486	2,422
2	2	0	2,078	2,286	5,296	5,129
3	3	0	2,809	3,332	7,653	7,819
4	4	0	3,956	4,298	11,463	10,553
5	5	0	4,718	5,302	14,548	13,225
6	6	0	5,187	6,319	15,157	15,932
7	0	1	1,329	1,105	2,325	1,954
8	1	1	2,456	2,111	4,899	4,653
9	2	1	3,798	3,118	7,985	7,351
10	3	1	4,798	4,124	11,256	10,052
11	4	1	5,687	5,131	13,986	12,754
12	5	1	8,043	6,136	16,891	15,452
13	6	1	9,265	7,143	19,712	18,151
14	0	2	1,446	1,935	4,659	4,185
15	1	2	2,248	2,943	6,747	6,883
16	2	2	3,351	3,949	10,956	9,582
17	3	2	4,802	4,956	14,165	12,283
18	4	2	7,959	5,962	16,875	14,988
19	5	2	9,736	6,968	19,985	17,685
20	6	2	8,923	7,972	22,984	20,385

A Figura 7 apresenta, utilizando os mesmos cenários da Figura 6, uma comparação entre os resultados do modelo de estimação e as medições realizadas.

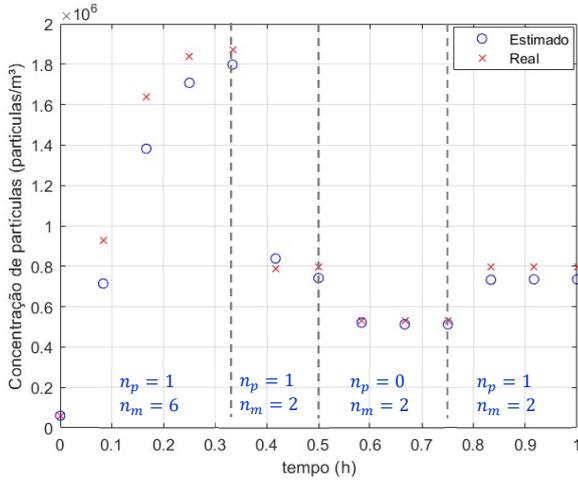


Fig. 7: Concentração de partículas medidas versus resultado do modelo de estimação em quatro cenários diferentes

A ferramenta utilizada para quantificar o desempenho 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 (ASTM, 2019)*. 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 o coeficiente de correlação r , calculado por (9) e o Erro Médio Quadrático Normalizado ($NMSE$ -*Normalized Mean Square Error*), obtido por (10), que é uma medida da magnitude do erro de estimação relativo.

$$r = \frac{\sum_{i=1}^n [(C_{ri} - \bar{C}_r)(C_{ei} - \bar{C}_e)]}{\sqrt{\sum_{i=1}^n [(C_{ri} - \bar{C}_r)^2] [\sum_{i=1}^n (C_{ei} - \bar{C}_e)^2]}} \quad (9)$$

$$NMSE = \frac{\sum_{i=1}^n (C_{ei} - C_{ri})^2 / n}{[(\bar{C}_r)(\bar{C}_e)]} \quad (10)$$

Para que o modelo tenha um bom desempenho de acordo com os critérios da ASTM D-5153-2019 e seja considerado um bom modelo, precisa conter um $r \geq 0,9$ e um $NMSE \leq 0,25$. Na tabela 5 encontram-se os critérios calculados para cada um dos vinte cenários. Observa-se que o modelo representa bem o processo, pois em doze dos vinte cenários, os critérios ficaram dentro dos intervalos recomendados. Dos oito cenários restantes, dois deles (cenários 7 e 14) se destacam negativamente por estarem com os critérios calculados distantes dos intervalos recomendados. Uma das soluções para esse problema consiste em uma correção do modelo através do ajuste de seus parâmetros.

4.2 Correção do modelo de estimação

Com o intuito de melhorar o desempenho do modelo, aplicou-se uma técnica de otimização não-linear com restrições para se ajustar seus parâmetros, que foram obtidos através das medições com o contador de partículas. Dentre os parâmetros

do modelo, os que se encontram abaixo são os que apresentaram uma grande variação nos ensaios que levaram à sua determinação, conforme observa-se em (11) a (15).

Tabela 5: Análise estatística de desempenho 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

$$710.562 \leq G_p \leq 1.838.562 \quad (11)$$

$$1.397.451 \leq G_m \leq 1.707.564 \quad (12)$$

$$56.884 \leq D \leq 146.756 \quad (13)$$

$$51.541 \leq C_{S0} \leq 69.460 \quad (14)$$

$$9.654.829 \leq C_0 \leq 11.287.652 \quad (15)$$

Para ajustar esses parâmetros, foram criadas cinco variáveis auxiliares ($G_{px}, G_{mx}, D_x, C_{S0x}, C_x$), que os multiplicam, sendo seu intervalo de variação conforme (16) a (20), proporcionais aos intervalos de (11) a (15).

$$0,569 \leq G_{px} \leq 1,471 \quad (16)$$

$$0,924 \leq G_{mx} \leq 1,131 \quad (17)$$

$$0,569 \leq D_x \leq 1,468 \quad (18)$$

$$0,857 \leq C_{S0x} \leq 1,155 \quad (19)$$

$$0,925 \leq C_{0x} \leq 1,081 \quad (20)$$

Portanto, o modelo a ser otimizado passa a ser conforme (21) a (23).

$$C_{ST} = \left(C_{S0} C_{S0x} - \left(\frac{\beta}{\alpha} \right) C_0 C_{0x} \right) e^{-\alpha t} + \left(\frac{\beta}{\alpha} \right) C_0 C_{0x} \quad (21)$$

$$[\varepsilon_v r(1 - \eta_r) - \varepsilon_v] = -\alpha \quad (22)$$

$$(1 - r)(1 - \eta_n) + \frac{(n_p G_p C_{px} + n_m G_m C_{mx} - DD_x)}{C_0 n} = \beta \quad (23)$$

A otimização do modelo foi executada 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, representada em (24), que precisa ser minimizada, consiste no erro existente entre os valores de concentração de partículas

estimados pelo modelo (C_{est}) e os medidos (C_{med}), base de dados de medição apresentada na Tabela 4. O vetor x e seus intervalos de variação, que representam as restrições da função, são provenientes de (16) a (20), sendo $x_1 = G_{px}$, $x_2 = G_{mx}$, $x_3 = D_x$, $x_4 = C_{SOx}$, $x_5 = C_{0x}$.

$$\min_x \text{abs}(\text{erro}(x)) = |C_{est} - C_{med}| \quad (24)$$

Sujeito a:

$$\begin{aligned} 0,732 &\leq x_1 \leq 1,304 \\ 0,924 &\leq x_2 \leq 1,131 \\ 0,569 &\leq x_3 \leq 1,468 \\ 0,857 &\leq x_4 \leq 1,155 \\ 0,925 &\leq x_5 \leq 1,081 \end{aligned}$$

Ao incluir a função *fmincon* no *script* desenvolvido, para resolver o problema de otimização não-linear com restrições apresentado em (24), encontrou-se um conjunto de parâmetros G_{px} , G_{mx} , D_x , C_{SOx} , C_{0x} diferentes para cada um dos vinte cenários, conforme Tabela 6, onde observa-se também que houve uma melhora significativa nos critérios de desempenho do modelo, r e $NMSE$ com os parâmetros ajustados.

Tabela 6: Análise estatística de desempenho do modelo após ajuste nos parâmetros

Cenário	r	$NMSE$	G_{px}	G_{mx}	D_x	C_{SOx}	C_{0x}
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

Observa-se na Figura 8 a simulação executada do sensor por software, em que os valores encontrados pelo modelo de estimação corrigido apresentam um erro menor, se comparado ao valor estimado pelo modelo antes da correção de seus parâmetros.

5. SENSOR POR SOFTWARE

A estrutura do sensor por software pode ser visualizada na Figura 9, com a adição da etapa de correção dos parâmetros do modelo. As grandezas físicas capturadas por sensores e inseridas em tempo real no modelo são a qualidade do ar externo (C_0) em que pode ser utilizado um sensor de qualidade do ar de baixo custo, um sensor de presença na porta da sala para contabilizar o número de pessoas (n_p) e sensores nas máquinas para detectar quando estão em operação (n_m).

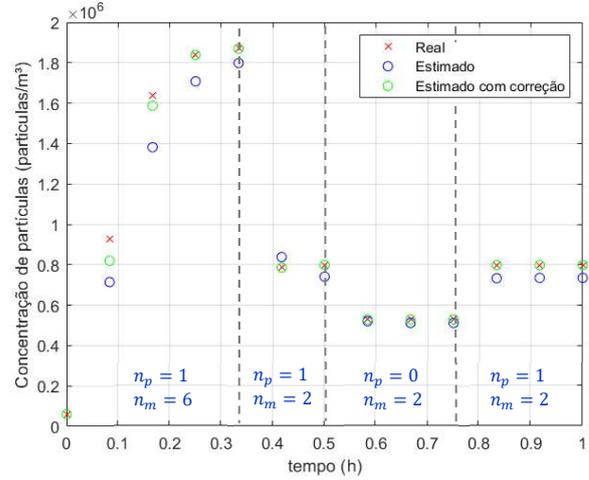


Fig. 8: Concentração de partículas medidas *versus* modelo de estimação sem correção *versus* modelo de estimação com correção em 4 cenários diferentes

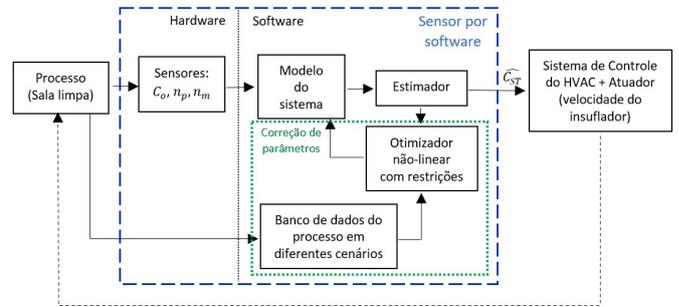


Fig. 9: Estrutura do sensor por software

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) precisam ser obtidos do sistema de controle do HVAC e inseridos no modelo constantemente, para que se mantenha uma boa estimativa.

Para o sensor por software, quando não automatizado, não ter sua precisão diminuída 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 *damp*er do sistema HVAC) e a taxa de trocas de ar por hora (n).

5.1 Proposta de melhoria da eficiência energética do sistema HVAC da sala limpa

A concentração de partículas estimada pelo sensor por software 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 de modo que a concentração de partículas esteja sempre dentro dos limites determinados pela norma NBR ISO 14644 (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.

A Figura 10 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. Portanto, ao invés de o sistema HVAC operar sempre em um valor fixo $n = 8$, o operador pode reduzir para $n = 5$ quando a sala estiver em repouso ou com pouca ocupação e/ou utilização (cenários 1, 2, 3, 7, 8, 9, 14 e 15). Nesses casos, é possível reduzir a velocidade do insuflador em 37,5%. A redução no consumo de energia do insuflador pode chegar a 75,6%, se calculada pela Lei da Afinidade (White, 2002), conforme a Equação 25, que relaciona velocidade e consumo de energia em motores que atuam como bombas escoadoras de fluidos, onde P é o consumo de energia em W e Q é a vazão de ar movimentada pelo insuflador em m^3/s .

$$\frac{P_1}{P_2} = \left(\frac{Q_1}{Q_2}\right)^3 \quad (25)$$

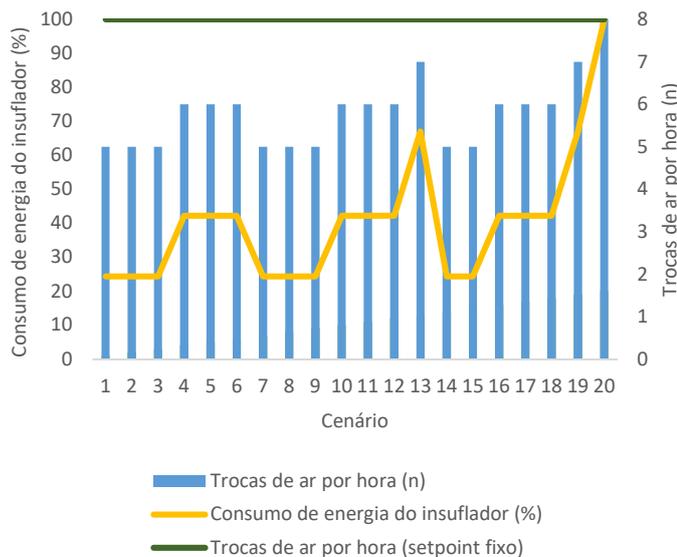


Figura 10: Taxa de trocas de ar por hora mínimo para cada cenário de utilização da sala e redução no consumo de energia

Observa-se na Figura 10 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.

6. CONCLUSÕES

Podemos concluir que o sensor por software contendo uma etapa de correção de parâmetros de seu modelo mostrou-se eficaz em estimar a concentração de partículas no interior da sala limpa, com um erro pouco significativo, mesmo se tratando de um modelo simplificado. A metodologia utilizada pode ser aplicada em qualquer sala limpa que necessite de um acompanhamento contínuo de sua qualidade do ar, visando uma melhoria na eficiência energética de seu sistema de climatização, mais especificamente do insuflador que controla o fluxo de ar ultra limpo que adentra a sala limpa. No estudo de caso aqui abordado, verificou-se a possibilidade de redução no consumo de energia em quase todos os cenários utilização da sala limpa, podendo a redução do consumo chegar a 75,6%, quando a sala estiver em repouso ou com pouca utilização.

AGRADECIMENTOS

O presente trabalho foi realizado com apoio do itt Chip - Instituto Tecnológico de Semicondutores da Unisinos. Os autores agradecem ao coordenador Prof. Celso Peter.

REFERÊNCIAS

- ASTM (2019). Standard Guide for Statistical Evaluation of Indoor Air Quality Models. *American Society for Testing and Materials*, West Conshohocken, EUA.
- Brown, W. K. (1986). Fundamental cleanroom concepts. *ASHRAE Transactions*, v. 92, p. 272-288.
- IEC Recommended Practices 12 (1993). Considerations in cleanroom design. *Institute of Environmental Sciences and Technology*. Schaumburg, EUA.
- Jaisinghani, R. A. (2001). Air handling considerations for cleanrooms. *Interphex Conference*, Março 20-22, Philadelphia, EUA.
- Kircher, K.; Shi, X.; Patil, S. (2010). Cleanroom energy efficiency strategies: Modeling and simulation. *Energy and Buildings*, v. 42, p. 282-289.
- Levy, J.; Ohadi, M.; Choo, K. (2015). Energy analysis cleanrooms in na academic research building. *ASHRAE Transactions*, v. 121, p. 71-83.
- Loomans, M; Molenaar, P.; Kort, H. (2019). Energy demand reduction in pharmaceutical cleanrooms through optimization of ventilation. *Energy & Buildings*, v. 202, p. 1-11.
- Mathew, P.; Tschudi, W.; Sartor, D. (2010). Cleanroom energy efficiency: Metrics and benchmarking. *ASHRAE Journal*, v. 52.
- Morrison, P. W. (1973). *Environmental control in electronic manufacturing*. Van Nostrand Reinhold, New York.
- Sun, W. (2010). Development of cleanroom required airflow rate model based on establishment of theoretical basis and label validation. *ASHRAE Transactions*, v. 116, P. 87-97.
- White, F. (2002). *Mecânica dos fluidos*. Ed. McGraw-Hill.
- Xu, Z. (2003). Air cleaning technology principle. Beijing Science Press, Pequim, China.
- Zhou, L. (2017). Studies on comparison of particle concentration models for cleanroom. *Procedia Engineering*, v.205, p. 3308-3315.