



Sensor fusion applied to the estimate of luminous intensity (LUX) in practical class

Fusão de sensores aplicada à estimativa da intensidade luminosa (LUX) em aula prática

ACORSI, Matheus Gabriel ⁽¹⁾; SILVA, Thiago Lima da⁽²⁾; REGAZZO, Jamile Raquel⁽³⁾; TABLE, Rubens André⁽⁴⁾; BAESSO, Murilo Mesquita⁽⁵⁾; GIMENEZ, Leandro Maria⁽⁶⁾

⁽¹⁾ 0000-0002-3318-7882; Universidade de São Paulo. Piracicaba, São Paulo (SP), Brasil. matheusacorsi@usp.br

⁽²⁾ 0000-0002-6954-0414; Universidade de São Paulo. Piracicaba, São Paulo (SP), Brasil. thiagolim@usp.br

⁽³⁾ 0000-0002-0329-1208; Universidade de São Paulo. Piracicaba, São Paulo (SP), Brasil. jamile.regazzo@usp.br

⁽⁴⁾ 0000-0001-7771-8078; Universidade de São Paulo. Pirassununga, São Paulo (SP), Brasil. table@usp.br

⁽⁵⁾ 0000-0003-4778-6015; Universidade de São Paulo. Pirassununga, São Paulo (SP), Brasil. baesso@usp.br

⁽⁶⁾ 0000-0002-6408-2688; Universidade de São Paulo. Piracicaba, São Paulo (SP), Brasil. lmgimenez@usp.br

O conteúdo expresso neste artigo é de inteira responsabilidade dos/as seus/as autores/as.

ABSTRACT

In the last ten years, the development of sensors with greater accuracy and precision due to improvements in manufacturing processes has enabled the expansion of their use in several areas. However, the purchase price, mainly of products from renowned manufacturers, in view of their applications, can make simpler projects unfeasible. The sensor data fusion technique is a viable alternative to resolve this issue, as mathematical models can be proposed and used in different situations. These models allow improving the data obtained in order to generate reliable information. Therefore, the objective of this work was to verify the performance of multiple linear regression applied to the fusion of redundant quantitative data from 5mm LDR sensors in estimating the luminous intensity (LUX) in simulated scenarios. To carry out the experiment, 3 LDR (Light Dependent Resistor) sensors, 3 LM393 signal conditioners, 1 USB 6009 DAQ data acquisition board (14 bits), 1 LT40 Extech luxmeter, in addition to the LabView software were used. It was found that LDR A and B sensors showed higher levels of accuracy. Furthermore, a significant improvement in the level of accuracy was found when combining data from sensors A and B in the form of multiple linear regression.

RESUMO

Nos últimos dez anos, o desenvolvimento de sensores com maior acurácia e precisão devido a melhorias nos processos fabris tem possibilitado ampliação do seu uso em diversas áreas. Contudo, o valor de aquisição, principalmente de produtos de fabricantes consagrados, frente as suas aplicações pode inviabilizar projetos mais simples. A técnica de fusão de dados de sensores apresenta-se como uma alternativa viável na resolução desta questão, pois modelos matemáticos podem ser propostos e usados em diversas situações. Esses modelos permitem melhorar os dados obtidos a fim de gerar informações confiáveis. Sendo assim, objetivo deste trabalho foi verificar o desempenho da regressão linear múltipla aplicada à fusão de dados quantitativos redundantes de sensores LDR 5mm na estimativa da intensidade luminosa (LUX) em cenários simulados. Para realização do experimento foram usados 3 sensores LDR (Light Dependent Resistor), 3 condicionadores de sinal LM393, 1 placa de aquisição de dados DAQ USB 6009 (14 bits), 1 luxímetro LT40 Extech, além do software LabView. Verificou-se que os sensores LDR A e B apresentaram maiores níveis de acurácia. Ainda, foi constatada significava melhora no nível de acurácia quando combinados os dados dos sensores A e B na forma de regressão linear múltipla..

INFORMAÇÕES DO ARTIGO

Histórico do Artigo:

Submetido: 28/01/2023

Aprovado: 23/03/2023

Publicação: 10/04/2023



Keywords:

instrumentation;
mathematical modeling;
redundant quantitative data

Palavras-Chave:

instrumentação;
modelagem matemática;
dados quantitativos
redundantes

Introdução

À medida que a tecnologia de mensuração de grandezas utilizando sensoriamento se desenvolve, a exigência pela acurácia e diminuição dos custos destes sensores desperta o interesse por métodos que aprimorem a qualidade dos dados e se apresentem como alternativa confiável e necessária ao tratamento das informações.

Métodos fundamentados na integração de dados medidos por vários sensores são opções para melhoria da precisão, a exemplo da fusão de sensores. Segundo Anjos (2017), essa técnica usa mais de um sensor da mesma característica ou não que extrai informações combinadas aumentando a precisão da medição ou suprindo falhas uns dos outros. Para a fusão de sensores um conjunto de dados é obtido e aplica-se a ele um modelo de correção e extrai a sua saída, com a vantagem de aplicação de técnica de diagnóstico automático de falhas, sendo que em aquisição de dados por sensor isolado este processo é feito de forma manual e demorado (Neves, 2017).

A fusão de sensores tem sido aplicada em diversas áreas do conhecimento devido à sua flexibilidade e precisão. De acordo com Yang et al. (2022) a fusão de sensores é capaz de melhorar o desempenho da estimativa de medições locais coletadas de diferentes sensores, superando todas as estimativas de um sensor de estado local. A implantação de sistemas de redes de sensores amplia o uso da fusão multissensores, principalmente em sistemas descentralizados onde a cooperação de outros sensores compensam deficiências específicas, como detecções perdidas e alarmes falsos, melhorando acurácia e robustez na estimativa (Li et al., 2019).

A fusão desses dados se caracteriza pela agregação e ou combinação de várias medidas de probabilidade, podendo ser usado aprendizado de máquina, estatística, teoria de estimativa e processamento de sinal, onde as combinações são produtos de vários conjuntos de dados que reduzem a incerteza (Taylor & Bishop, 2019). Assim sendo, algoritmos usados para fusão podem ser determinados de acordo com tipo de informação adquirida e as características de desempenhos e operação dos sensores (Filho, 2007).

Diante da disponibilidade de uso da técnica da fusão de sensores, vários algoritmos foram propostos como filtragem de kalman (Sun et al, 2017), cálculo da “média” sobre as informações fornecidas por sensores, incluindo assim a média ponderada (Zang & Wang, 2021), algoritmo de estimação de máxima probabilidade (Santana et al., 2018), função de verossimilhança (Papa et al., 2019), lógica fuzzy (Song et al., 2022) dentre outros.

Sendo assim, a finalidade deste trabalho foi verificar o desempenho da fusão de dados quantitativos redundantes de sensores do tipo Light Dependent Resistor – LDR na estimativa da intensidade luminosa (LUX) em cenários simulados, aplicando ajustes e estabelecendo métricas estatísticas pelo método de regressão linear múltipla.

Desenvolvimento


O experimento foi realizado no dia 18/05/22 no horário reservado à disciplina de instrumentação e automação para sistemas agrícolas em aula remota síncrona ofertada para o Programa de Pós-graduação em Engenharia de Sistemas Agrícolas da Escola Superior de Agricultura Luiz de Queiroz - Esalq, Piracicaba-SP.

Material e características

Para realização do experimento foram usados 3 sensores do tipo Light Dependent Resistor - LDR, formato circular de 5mm de diâmetro, resposta entre 350 e 820nm com relativa máxima na faixa dos 530 a 580nm, 3 condicionadores de sinal LM393, 1 placa de aquisição de dados DAQ USB 6009 (14 bits), 1 luxímetro LT40 Extech, conforme sistema apresentado na figura 1. Suas características técnicas (Datasheet) estão descritos na tabela 1.

Figura 1.

Sistema de aquisição de dados de luminosidade (LUX) por meio de sensores LDR, condicionador de sinal LM393, placa DAQ USB 6009 e luxímetro LT40 Extech.



Nota: 1. Sistemas de sensores e condicionadores 2. Placa de aquisição de dados DAQ USB 3. Luxímetro LT40.

Tabela 1.

Sensibilidade, resolução e alcance dos componentes utilizados no experimento.

Dispositivo	Sensibilidade	Resolução	Alcance
LDR 5mm	$\pm 2,7 \text{ k}\Omega @ 10 \text{ lux}$	N/A	0,1 - 10.000 lux
LM 393	N/A	5% FSO	N/A
DAQ USB 6009	0,6 mVcc	14 bits	N/A
Luxímetro LT40	$\pm 3 \%$ da leitura	0,1 lux	39.999 lux

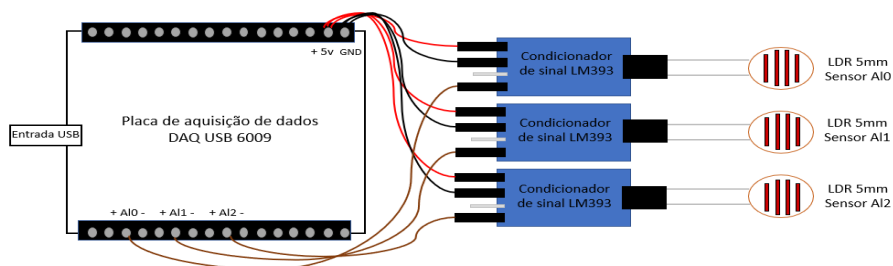
Funcionamento e processo de calibração

Para o funcionamento do sistema, os condicionadores de sinais foram ligados às portas analógicas disponíveis na DAQ. Estas entradas são usadas para medir variações de tensão de componentes analógicos que ao mensurar a grandeza alteram a resistência e assim varia a tensão, podendo operar em faixas de luz infravermelho, visível e ultravioleta. Cada sensor tem uma variação de resistência em função da luminosidade que é passada para o condicionador de sinal que por sua vez converte o sinal de resistência em tensão.

As saídas dos condicionadores de sinal (fios vermelhos) foram conectados numa porta de 5v e alimentados pela mesma entrada (fios pretos) GND da placa, os fios de sinal do condicionador (fios marrons) foram conectados às portas analógicas de tensão, alcance 0 a 10 Vcc da DAQ USB 6009, sendo elas analógico 0 (AIO), analógico 1 (AI1) e analógico 2 (AI2) conforme diagrama elétrico na figura 2.

Figura 2.

Representação do diagrama elétrico do sistema experimental de fusão de sensores centralizados.



Para visualização dos dados foi utilizado o software LabView 2013 (32 bit) que apresentava valores de amplitude (v) de cada sensor com taxa de amostragem de 5 Hz (cinco amostras por segundo) e resolução de 0,1 mVcc (mínima variação detectável). Para verificação

do funcionamento dos sensores, a de luz direta foi interrompida e em outro momento saturada nos receptores por meio de uma lanterna com emissor em LED, com temperatura de 6500K.

Na mensuração da grandeza, foi usado o luxímetro LT40 Extech calibrado onde também foi verificado diminuindo e saturando a incidência luminosa. Após este procedimento, passou-se ao processo de calibração da curva do Lux, em função da tensão gerada pelo sensor e do tempo, simulando cenários de baixa e alta luminosidade no mesmo ambiente que se encontravam todos os componentes.

Foram gerados 12.036 dados pelo software LabView que posteriormente foram transferidos e tratados no ambiente excel para aplicação da técnica de fusão de sensores pelo método da regressão linear múltipla.

Modelagem de dados

Como forma de estabelecer a relação entre as leituras de tensão provenientes de sensores LDR e a intensidade luminosa registrada pelo luxímetro, foram utilizados modelos regressivos combinando tais medidas. Para tanto, utilizou-se um conjunto de 9 amostras nesta etapa, ajustando modelos para os sensores A, B e C de forma individual, e de forma conjunta. Nesse sentido, foram testados modelos lineares, exponenciais, polinomiais e logarítmicos, priorizando a escolha do modelo de maior coeficiente de determinação (R^2) para cada cenário.

Para utilização dos dados dos diferentes sensores LDR de forma conjunta, foram exploradas duas estratégias. A primeira, consiste no cálculo da média aritmética entre dados do sensor A, B e C relativos a mesma leitura para posterior condução da análise de regressão. A segunda, explora a redundância de sensores por meio da regressão linear múltipla, em que cada sensor LDR representa uma variável independente (x) distinta, havendo seleção destas variáveis por meio do método stepwise.

Para verificar o desempenho dos modelos estabelecidos, utilizou-se um conjunto de dados independente contendo 7 amostras. Nesse sentido, foram estimados valores de intensidade luminosa a partir dos modelos estabelecidos utilizando-se de dados de sensores LDR, os quais foram comparados na forma de regressão linear com medidas de referência. Para analisar os modelos pré estabelecidos foram considerados quatro métricas de regressão: o coeficiente de determinação (R^2), erro médio (EM), erro absoluto médio (EAM) e root mean squared error (RMSE). Com efeito, em problemas de regressão procura-se selecionar o modelo que afira valores mais aproximados dos dados, assim sendo aquele que diminua os erros, esse representado pela diferença entre o valor real observado e o valor previsto pelo modelo.

Resultados e discussão

A partir do pareamento dos dados registrados na DAQ junto às leituras feitas com o luxímetro, foi possível estabelecer a relação entre os valores de tensão oriundos dos sensores LDR com a intensidade luminosa. Tal relação é expressa pelos modelos matemáticos apresentados na Tabela 2.

Tabela 2.
Modelos matemáticos obtidos entre dados provenientes dos sensores e valores de referência.

Y	X	R ²	Modelo
ux L	Tensão (v) – Sensor A	.999	$Y=2732.2*\exp(-2.071x)$
ux L	Tensão (v) – Sensor B	.997	$Y=2163*\exp(-2.188x)$
ux L	Tensão (v) – Sensor C	.990	$Y=5292*\exp(-2.167x)$
ux L	Tensão (v) – Sensor média (A+B+C/3)	.998	$Y=3153.7*\exp(-2.12x)$
n(Lux) L	Tensão (v) – Sensor A (x ₁) e B (x ₂)	.993	$Y=(21.670*x_1)+(-24.098*x_2)+4.789$

Quando avaliados de forma individual, os dados oriundos de cada sensor LDR são melhores representados a partir de um modelo exponencial com formato descendente, alcançando valores de R² superiores a 0,99. De forma similar, o modelo que combina os dados dos três sensores LDR por meio de uma média aritmética também apresentou melhor aderência ao modelo exponencial, com R² de 0,998.

Ao combinar os dados dos sensores LDR por meio da regressão linear múltipla associada ao método stepwise para seleção de variáveis preditoras, verificou-se que os dados do sensor C não foram incluídos no modelo por não apresentarem significância no teste estatístico (p-value > 0,05). Dessa forma, o modelo obtido associa dados oriundos sensor A e B na predição da intensidade luminosa, apresentando R² de 0,993.

A aplicação da regressão linear múltipla, usando método stepwise, favoreceu a definição dos modelos e o rearranjo de combinações, pois este método indicou os melhores preditores para inclusão na análise com destaque na resolução do problema proposto, por isso os dados do sensor C foram retirados, contribuindo assim para menor tempo de análise e ajustes, menor exigência de processamento computacional, melhor desempenho na obtenção dos resultados objetivos e claros, sem interferência significativa na acurácia e métricas estatísticas.

Essa técnica tem sido bastante usada em modelagem com aplicação da regressão linear múltipla com combinações de dados, pois a definição dos preditores está relacionada ao nível de significância marginal na análise estatística com a probabilidade pré-definida (valor-p), porém nem sempre esta técnica define os melhores ajustes das variáveis (Akinwande et al., 2015), o que não ocorreu neste estudo devido a observação das melhores métricas estatísticas com a exclusão dos dados do sensor C na combinação com os sensores A e B, indicado na stepwise.

A inserção de muitas variáveis combinadas para determinação de atributo alvo nem sempre propicia melhores resultados, fator observado neste estudo, confirmando a importância do uso da metodologia stepwise para esse tipo de análise. Serrone and Moretti (2023), utilizaram modelos ajustados de regressão linear múltipla para definição de classes de impacto ambiental na produção de clínquer e aplicaram também o método stepwise para predição das variáveis independente onde selecionou as que mais contribuíram para aumento dos impactos dentro de cada classe.

Outro ponto que deve ser observado é que o sensor C apresentou métricas estatísticas abaixo do sensor A, B e suas combinações, sendo identificado na análise de predição de variáveis de entrada como não significativas. Esse fato pode ter relação com uma possível degradação de sinal deste sensor, sendo assim necessário avaliações de observação de um banco de dados histórico de registros e o monitoramento em tempo real com aplicações de análises de regressão. Para Zang et al. (2023), a verificação de fluxos de sinais degradados contínuos em sensores é insuficiente, além disso, em determinados ambientes de industriais a segurança dos dados monitorados necessita ser preservada quanto a sua privacidade, o que exige ainda mais critérios na análise.

O uso da fusão de sensores também foi utilizada por Santos (2020) para associar vários sensores para alcançar precisão em um sistema para localização de robô móvel através de uso de algoritmo e a combinação dos dados de odometria. Em seu estudo, a média dos erros RMS linear e angular atingida, respectivamente, para a configuração com apenas o encoder, foi de 16,37 e 37,20, enquanto que configuração com encoder, IMU e kinect, apresentou 2,17 e 3,63, mostrando o desempenho do uso de vários sensores no resultados por meio de métricas estatísticas.

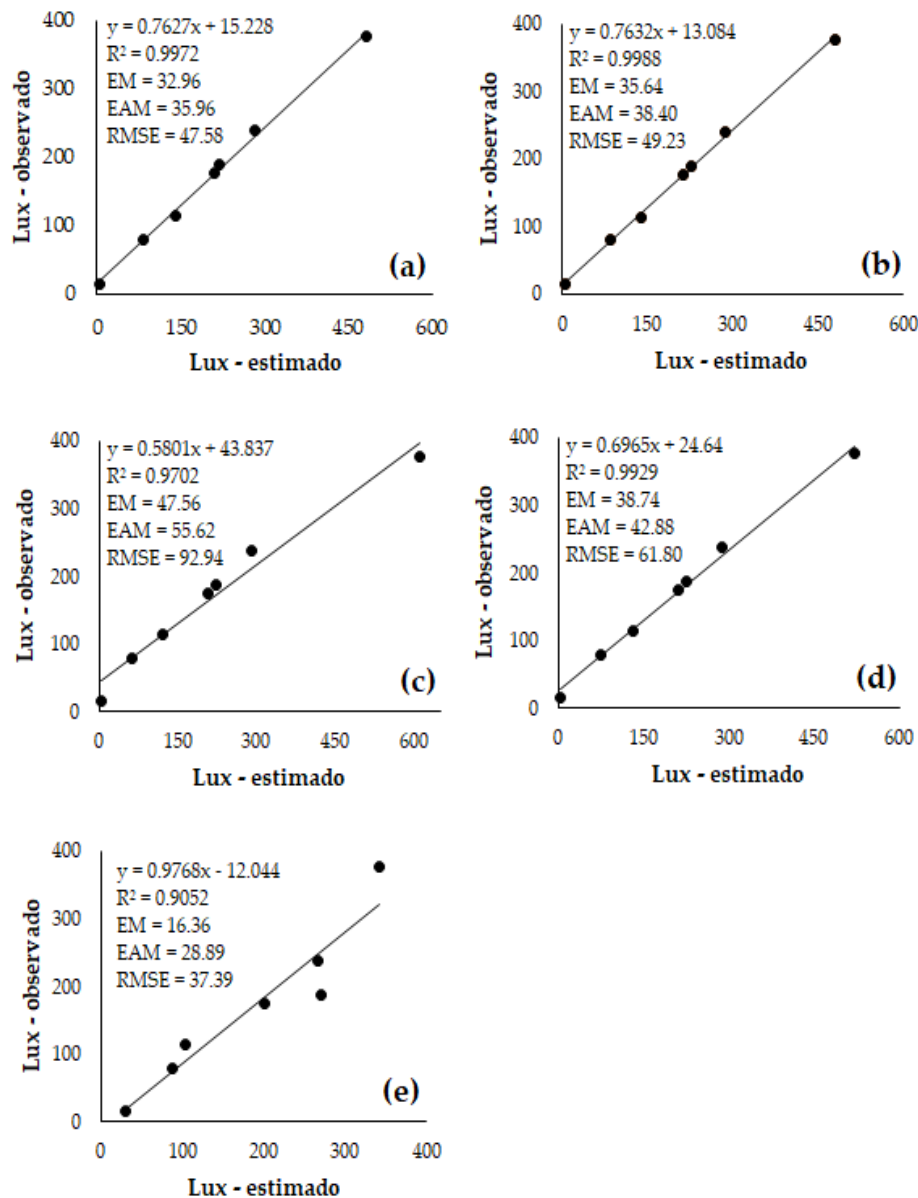
Li et al. (2022) utilizaram a fusão de sinais de emissão acústica e fotodiodo para fins de monitoramento de qualidade in-situ de fusão a laser seletiva. O método de fusão multi-sensor apresentado ampliou significativamente a precisão da classificação em virtude de um ligeiro aumento no tempo computacional em comparação com os métodos baseados em sensor único.

Para verificar o desempenho dos diferentes modelos obtidos, estes foram aplicados a um conjunto de dados independente, visando a extração de resíduos e inferências sobre precisão e acurácia dos sensores. Na Figura 2, são apresentados os gráficos ilustrando os

valores de luminosidade estimados a partir dos dados LDR em relação aos valores de referência, juntamente com valores de R², EM, EAM e RMSE.

Figura 2.

Relação entre dados de intensidade luminosa observada e estimada pelos modelos matemáticos obtidos a partir de dados individuais do sensor A (a), sensor B (b), sensor C (c), e da associação de dados pela média aritmética (d) e regressão linear múltipla (e).



Ao avaliar os resíduos relativos aos modelos individuais de cada sensor, verificou-se que o sensor A apresentou maior acurácia, com RMSE de 47,58 lux, seguido do sensor B e C, com RMSE de 49,23 e 92,94 lux. Quando os dados dos sensores foram combinados na forma de média aritmética, a acurácia foi reduzida, alcançando um RMSE de 61,80 lux.

Conforme Santana et al. (2018), elaboraram um sistema para localizar um robô móvel colocado em ambientes fechados. E a partir de simulações em Matlab, obtiveram resultados

em que a fusão foi apta a moderar os erros acumulativos no ponto determinado pela odometria, e ainda, ampliar a tolerância das perturbações na posição do robô.

Por fim, ao aplicar o modelo obtido pela regressão linear múltipla, foi possível alcançar os melhores resultados em termos de acurácia, com RMSE de 37,39 lux. Tal resultado se deve a exclusão dos dados oriundos do sensor C, que apresentou desempenho substancialmente inferior ao sensor A e B.

Conclusões

Com base no experimento realizado foi possível verificar o funcionamento dos sensores LDR junto a dispositivos de condicionamento de sinal e registro de dados, bem como, verificar o comportamento do sinal de resposta frente a variações de intensidade luminosa no ambiente.

Também, a partir do emprego de um luxímetro, foram obtidos diferentes modelos matemáticos relacionando a tensão registrada pelos sensores LDR e intensidade luminosa.

Ao aplicar os modelos obtidos, verificou-se que os sensores LDR A e B apresentaram maiores níveis de acurácia. Ainda, foi constatada significativa melhora no nível de acurácia quando combinados os dados dos sensores A e B na forma de regressão linear múltipla.

REFERÊNCIAS

- Anjos, J. H. P. (2017). *Técnicas de fusão de sensores aplicadas à construção e melhoria de desempenho de sistemas de medição* [Trabalho de conclusão de curso]. https://www2.dee.cefetmg.br/wp-content/uploads/sites/18/2017/11/TCC_2017_1_JHPAnjos.pdf
- Filho, M. B. D. C., Souza, J. C. S., & Schilling, M. Th. (2007). Sobre o problema da integração generalizada de dados. In *Sba: Controle & Automação Sociedade Brasileira de Automatica*. <https://www.scielo.br/j/ca/a/Zs7YpLgNq4T9MbSWFbm8BQz/?format=pdf&lang=pt>
- Li, J., Zhang, X., Zhou, Q., Chan, F. T. S., & Hu, Z. (2022). A feature-level multi-sensor fusion approach for in-situ quality monitoring of selective laser melting. *Journal of Manufacturing Processes*, 84(84), 913–926. <https://doi.org/10.1016/j.jmapro.2022.10.050>
- Li, T., Fan, H., García, J., & Corchado, J. M. (2019). Second-order statistics analysis and comparison between arithmetic and geometric average fusion: Application to multi-sensor target tracking. *Information Fusion*, 51(51), 233–243. <https://doi.org/10.1016/j.inffus.2019.02.009>
- Neves, F. (2017, March 7). *Introdução à Fusão de Sensores*. Embarcados - Sua Fonte de Informações Sobre Sistemas Embarcados. <https://www.embarcados.com.br/introducao-fusao-de-sensores-parte-1/>
- Akinwande, M. O., Hussaini, G. D., Shehu, U. G. Identifying the Limitation of Stepwise Selection for Variable Selection in Regression Analysis. *American Journal of Theoretical and Applied Statistics*. Vol. 4, No. 5, 2015, pp. 414-419. doi: 10.11648/j.ajtas.20150405.22
- Papa, G., Repp, R., Meyer, F., Braca, P., & Hlawatsch, F. (2019). Distributed Bernoulli Filtering Using Likelihood Consensus. *IEEE Transactions on Signal and Information Processing over Networks*, 5(2), 218–233. <https://doi.org/10.1109/tsipn.2018.2881718>
- Santana, B. A., Ushikoshi, T. D. A., Chagas, T. P., & Schnitman, L. (2018). Fusão de sensores aplicada à

localização de robôs móveis utilizando sistema especialista Fuzzy. *Anais Do Congresso Brasileiro de Automática*, 1(2525-8311).

Santos, H. Á. (2020). *Uma avaliação da contribuição da fusão de sensores de posicionamento relativo na precisão dos sistemas de localização de robôs móveis terrestres* [Dissertação de Mestrado].

Serrone, G. D., Moretti, L. A stepwise regression to identify relevant variables affecting the environmental impacts of clinker production, *Journal of Cleaner Production*, Volume 398, 2023, <https://doi.org/10.1016/j.jclepro.2023.136564>.

Song, F., Wu, J., Liu, B., Jiang, J., Li, Z., Song, C., Li, J., & Jin, G. (2022). Intelligent green tea fixation with sensor fusion technology. *Journal of Food Engineering*, 317(317), 110846. <https://doi.org/10.1016/j.jfoodeng.2021.110846>

Sun, S., Lin, H., Ma, J., & Li, X. (2017). Multi-sensor distributed fusion estimation with applications in networked systems: A review paper. *Information Fusion*, 38(38), 122–134. <https://doi.org/10.1016/j.inffus.2017.03.006>

Taylor, C. N., & Bishop, A. N. (2019). Homogeneous functionals and Bayesian data fusion with unknown correlation. *Information Fusion*, 45(45), 179–189. <https://doi.org/10.1016/j.inffus.2018.02.002>

Yang, F., Shi, L., Liang, Y., & Zheng, L. (2022). Global state estimation under sequential measurement fusion for clustered sensor networks with cross-correlated measurement noises. *Automatica*, 142(142), 110392. <https://doi.org/10.1016/j.automatica.2022.110392>

M. Zhang, W. Wang. (2021). Weighted adaptive partition for heterogeneous IoT data stream. *IEEE Internet of Things Journal*, 8 (20). <https://doi.org/10.1109/JIOT.2020.3045726>

Zhang, K., Xia, T., Wang, D., Chen, G., Pan, E., Xi, L. (2023). Privacy-preserving and sensor-fused framework for prognostic & health management in leased manufacturing system, *Mechanical Systems and Signal Processing*, V. 184, 2023,