



**UNIVERSIDADE FEDERAL DE OURO PRETO  
ESCOLA DE MINAS  
COLEGIADO DO CURSO DE ENGENHARIA DE  
CONTROLE E AUTOMAÇÃO**



**MARCÉLIA APARECIDA MARQUES DE OLIVEIRA**

**UM ESTUDO SOBRE OS SENSORES AUTOVALIDANTES**

**MONOGRAFIA DE GRADUAÇÃO EM ENGENHARIA  
DE CONTROLE E AUTOMAÇÃO**

**Ouro Preto, 2018**

MARCÉLIA APARECIDA MARQUES DE OLIVEIRA

## **UM ESTUDO SOBRE OS SENSORES AUTOVALIDANTES**

Monografia apresentada ao Curso de Engenharia de Controle e Automação da Universidade Federal de Ouro Preto como parte dos requisitos para obtenção do Grau de Engenheiro de Controle e Automação.

Orientador: Prof. Dr. Agnaldo José da Rocha Reis

Ouro Preto  
Escola de Minas – UFOP  
JULHO/2018

M528c Oliveira, Marcélia Aparecida Marques de.  
Um estudo sobre sensores autovalidantes [manuscrito] / Marcélia  
Aparecida Marques de Oliveira. - 2018.

45f.: il.: color; grafis; tabs.

Orientador: Prof. Dr. Agnaldo José da Rocha Reis.

Monografia (Graduação). Universidade Federal de Ouro Preto. Escola de  
Minas. Departamento de Engenharia de Controle e Automação e Técnicas  
Fundamentais.

1. Sensor. 2. Sensor Inteligente. 3. Autovalidação. 4. Validação Funcional. 5.  
Validação Tecnológica. I. Reis, Agnaldo José da Rocha. II. Universidade Federal  
de Ouro Preto. III. Título.

CDU: 681.5

Catálogo: [ficha@sisbin.ufop.br](mailto:ficha@sisbin.ufop.br)

Monografia defendida e aprovada, em 17 de julho de 2018, pela comissão avaliadora constituída pelos professores:



---

Prof. Dr. Agnaldo José da Rocha Reis - Orientador



---

Prof. Dr. Paulo Marcos de Barros Monteiro - Professor Convidado



---

M.Sc. Diógenes Viegas Mendes Ferreira – Professor Substituto Convidado

## RESUMO

Os sensores são dispositivos de amplo uso nas indústrias e no dia a dia, capazes de transformar variáveis físicas como, a velocidade, a temperatura, o nível e outras mais, em variáveis numéricas, facilitando o monitoramento e o controle de processos. É de suma importância que os valores de saída de um sensor estejam o mais próximo possível do real, com erro tendendo a zero. Porém, nem sempre os valores extraídos dos sensores são de confiança devido à falha do hardware do sensor ou à forma inadequada de se medir os dados. O desenvolvimento dos sensores inteligentes foi um avanço considerável, pois esses sensores têm microcontroladores ou microprocessadores embarcados que possuem softwares específicos capazes de realizar diversas funções. Uma das funções mais úteis que pode ser agregada a um sensor inteligente é a capacidade da autovalidação, ou seja, diminuir os erros de medição por si só, sem ajuda de nenhum dispositivo externo, fazendo com que o sensor tenha uma alta sensibilidade a problemas de funcionamento. O sensor autovalidante possui um módulo de validação de dados que fornece informações adicionais, indicando o nível de qualificação ou de confiança dos dados medidos. Objetiva-se com este trabalho mostrar a importância da calibração dos sensores, detalhar os métodos utilizados para a realização da autovalidação e mostrar os benefícios empregados ao seu uso e os avanços nessa área.

Palavras-chave: Sensor, Sensor Inteligente, Autovalidação, Validação Funcional, Validação tecnológica

## ABSTRACT

The sensors are devices widely used in industries and day-to-day, capable of transforming physical variables such as speed, temperature, level and others into numerical variables, making it easier to monitor and control processes. It is extremely important that the output values of a sensor are as close as possible to the actual one, with error tending to zero. However, values extracted from sensors are not always reliable due to sensor hardware failure or improper measurement of data. The development of intelligent sensors has been a considerable advance since these sensors have microcontrollers or embedded microprocessors that have specific software capable of performing several functions. One of the most useful functions that can be added to an intelligent sensor is the ability of self-validation, that is, to reduce measurement errors by itself, without the aid of any external device, making the sensor highly sensitive to operation. The self-validating sensor has a data validation module that provides additional information indicating the level of qualification or reliability of the measured data. The objective of this work is to show the importance of sensor calibration, to detail the methods used to perform self-validation and to show the benefits of its use and advances in this area.

Keywords: Sensor, Smart Sensor, Autovalidation, Functional Vaidation, Technological Validation

## LISTA DE ABREVIATURAS E SIGLAS

AC - Alta Confiabilidade;

AS - Aproximação Estocástica;

ASIC - Circuitos Integrados Específicos de Aplicativos;

BC - Baixa Confiabilidade;

CRM - Matriz de Referência de Calibração do Sensor;

COG – Centro de Gravidade;

DSP – Processador de Sinais;

ETEs – Estações de Tratamento de Águas Residuais;

FPGA - *Field Programmable Gate Array*;

GK - Kernels Gaussianos;

IEEE - Instituto de Eletricidade Engenheiros de Eletrônica e Eletrônica;

IV - Incerteza Validada;

MC - Média Confiabilidade;

MCU- Unidade Microcontroladora;

MNF - Modelo Neuro-Fuzzy;

NLPCA - *Nonlinear Principal Components Analysis*;

PCA - Análise de Componentes Principais;

RBE - Estimativa de Polarização Reduzida;

RTD - Termômetros de resistência;

SEVA - *Self Validating Sensor*;

SIF – Sistema de Inferência Fussy;

SVM - Status de Valor Medido;

USIC- Circuito de Interface de Sensor Universal;

VBPCA – *Variational Bayesian principal Component Analysis*;

VLSI - *Very Large Scale Integration*;

VMV - Valor da Medida Validado;

## LISTA DE FIGURAS

Figura 1 – Funcionamento de Um Sensor.....	13
Figura 2 – Funcionamento de um Transdutor.....	14
Figura 3 – Típico Sistema de Medição.....	16
Figura 4 – Rede Neural Auto-Associativa.....	21
Figura 5 – Compensação do Sensor Inteligente.....	22
Figura 6 – Treinamento do MNF.....	23
Figura 7 – Modelagem do Sistema de Auto-Validação.....	23
Figura 8, 8a, 8b, 8c – Funções de Pertinência das Entradas.....	24
Figura 9 – Tecnologia do sensor SEVA.....	25
Figura 10 – Arquitetura do Sensor SEVA.....	26
Figura 11 – Matriz de Referência de Calibração do Sensor.....	29
Figura 12 – Hardware da Primeira Geração do Sensor SEVA.....	31
Figura 13 – Diagrama de Blocos Funcional da USIC.....	33
Figura 14 – Etapas da Produção de Cerveja Artesanal.....	39

## LISTA DE TABELAS

Tabela 1. Medidas Mecânicas.....	15
Tabela 2- Parâmetro de Status.....	28

## SUMÁRIO

1. Introdução.....	13
1. Objetivos.....	14
1.1. Objetivo Geral.....	14
1.1.1. Objetivos Específicos .....	14
1.2. Justificativa do Trabalho.....	14
1.3. Estrutura do Trabalho .....	15
2. Revisão Bibliográfica .....	16
2.1. Sensor.....	16
2.2. Transdutor .....	17
2.3. Sensor Inteligente.....	18
2.4. Sensores Autovalidantes.....	20
3. Métodos de Autovalidação .....	22
3.1. Validação Funcional.....	22
3.1.1. Métodos Numéricos.....	22
3.1.2. Inteligência Artificial para Validação de Sensor.....	22
3.1.3. Abordagem Baseada em Modelo .....	23
3.1.4. Abordagem Baseada em Redes Neurais .....	23
3.1.5. Abordagem Baseada em Redes Neurais Auto-Associativas.....	24
3.1.6. Modelo Neuro-Fuzzy (MNF).....	26
3.2. Validação Tecnológica.....	28
3.2.1. Modelo SEVA .....	29

4. SEVA.....	31
4.1. Parâmetros de Saída do Sensor SEVA.....	31
4.2. Desenvolvimento de Pesquisa de Diagnóstico de Falha de Sensor e Reconstrução de Sinal e Algumas Aplicações.....	33
5. Estudo de Caso:.....	41
6. Conclusão e Sugestões para Trabalhos Futuros.....	44
Referências.....	45

## 1. INTRODUÇÃO

A utilização de instrumentos de medição na indústria para verificar as condições do processo industrial é muito importante. Para isso, o uso de sensores nos instrumentos de medição assim como o de transdutores são empregados afim de realizar a transformação de um parâmetro físico em uma variável numérica para expressar o valor desse parâmetro em um gráfico ou monitor para que assim o processo possa ser controlado. É necessário que as medições realizadas estejam precisas, seja por questões de segurança, ou por questões de produtividade. Com o tempo, os sensores que atuam na planta de um processo industrial, independentemente da sua qualidade, começam a se descalibrar e se desgastar, ou seja, passam a não ter coerência nos valores indicados. Esse tipo de desgaste recebe nome de descalibração, onde a curva de calibração começa a se deformar, fazendo com que o sinal que se refere ao valor medido não corresponda mais ao valor da variável física. Essa descalibração pode trazer muitos malefícios ao processo e grandes transtornos dependendo da área de atuação como a falta de controle do processo, a diminuição da qualidade do produto final, riscos à segurança, dentre outros.

Como esses desgastes são inevitáveis, é importante que a realização da calibração seja realizada no momento certo para que a precisão e exatidão que os processos industriais exigem, estejam adequadas. Muitas vezes para calibrar um sensor é necessário, que o processo pare para se retirar o sensor e leva-lo ao laboratório, fazendo com que o processo fique ocioso enquanto se realiza a calibração. Segundo (HINES E GARVEY, 2007), não respeitar os programas de manutenção pode trazer transtornos para o processo, que reflete na qualidade do produto, causando perdas econômicas e acidentes devido a um controle com sinais de realimentação imprecisos. Dependendo da frequência com que a manutenção é realizada, defeitos nos sensores podem passar despercebidos por muito tempo, mas uma manutenção manual se torna desnecessária nos sensores que estejam calibrados, podendo gerar um envelhecimento precoce dos componentes.

Os sensores autovalidantes surgiram com a proposta de eliminar esses problemas de funcionamento. Segundo (BHUYAN,2013), “Um módulo de validação de dados incluído no sensor deve fornecer dados adicionais que indicam o nível de qualificação ou de confiança dos dados medidos”. Para detectar a necessidade de calibrar o sensor novamente, são utilizados alguns métodos como: Método Numérico, Método de Falhas com Base na Alteração da Distribuição, Método de Falhas com Base na estimativa de Dados Locais, Inteligência Artificial

para Validação de Sensor, Abordagem Baseada em Modelo e Abordagem Baseada em Redes Neurais, dentre outros.

Existem dois tipos de classificação da função de autovalidação, a funcional e a tecnológica. A validação funcional tem como função detectar a consistência da medida ou da estimativa que o sensor produz ou dos recursos que os algoritmos de estimação usam. O sistema deve ser capaz de detectar a falha e isolá-la. A autovalidação possui um método clássico de detecção de falha do sensor que consiste em realizar a verificação das variáveis mensuráveis de uma planta levando em consideração uma tolerância dos valores nominais nas condições normais. As técnicas de detecção de falhas se baseiam em técnicas numéricas que dependem de modelagem matemática do sistema. A validação tecnológica aplicada aos sensores tem a capacidade de autodiagnosticar através de computação interna, baseando-se na experiência do projetista e na comunicação digital para realizar a transmissão de dados de medida, dados de manutenção e o diagnóstico de forma simultânea. A detecção de falha é realizada internamente, através de um microprocessador embutido, onde é usado o conhecimento do fabricante do sensor para que se possa fazer o autodiagnóstico e correção das medidas.

## **1.2. Objetivos**

### **1.2.1. Objetivo Geral**

Desenvolver uma pesquisa sobre os sensores autovalidantes desde o seu surgimento até a atualidade.

### **1.2.2. Objetivos específicos**

- Estudar sensores e transdutores;
- Estudar sensores inteligentes;
- Estudar sensores autovalidantes;
- Pesquisar métodos de autovalidação;
- Pesquisar Aplicações.

## **1.3. Justificativa do Trabalho**

Os estudos realizados neste trabalho têm por justificativa o interesse em contribuir com a pesquisa sobre a importância da calibração nos sensores, o que os sensores autovalidantes podem contribuir nessa área, mostrar o desenvolvimento da tecnologia de autovalidação e alguns métodos dessa mesma tecnologia.

#### **1.4. Estrutura do trabalho**

O Capítulo 1 descreve o problema e apresenta a proposta do trabalho, citando os pontos relevantes da investigação. No capítulo 2, apresenta-se uma revisão dos conceitos básicos de sensores, transdutores, sensores inteligentes e sensores autovalidantes, para introduzir um pouco mais o assunto que será abordado. São analisadas também as particularidades do SEVA. No capítulo 3, há uma descrição dos modelos de aplicação do sensor autovalidante. No capítulo 4, trata-se de algumas de suas especificações do sensor SEVA, assim como um desenvolvimento de pesquisa do hardware do sensor SEVA e exemplos de aplicações realizadas com o sensor. No capítulo 5, tem-se um estudo de caso. No capítulo 6, tem-se a conclusão desta pesquisa e sugestões para trabalhos futuros.

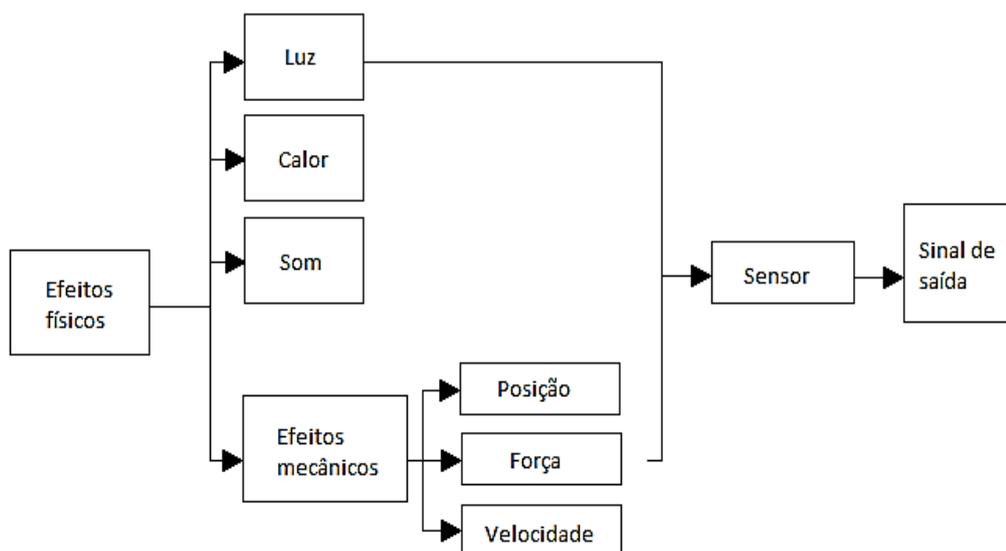
## 2. REVISÃO BIBLIOGRÁFICA

Neste capítulo é apresentado conceitos sobre Sensor (2.1); Transdutor (2.2); Sensores inteligentes (2.3) e Sensores autovalidantes (2.4).

### 2.2. Sensor

Os sensores são dispositivos sensíveis a alguma energia do ambiente, podendo ser ela cinética, térmica, luminosa, que possa relacionar uma grandeza que precisa ser mensurada, como: temperatura, pressão, velocidade, corrente, aceleração, posição, etc. Através dessa grandeza, um sinal de saída é gerado de acordo com a indicação da Figura 1.

Nem sempre os sensores possuem recursos elétricos para ser aplicado em um sistema de controle, sendo necessário o tratamento do sinal de saída antes da sua leitura no sistema de controle. Geralmente é utilizado um circuito de interface para produção de sinal de saída que é legível para o controlador. Os sensores podem ser analógicos ou digitais. Os sensores analógicos podem assumir qualquer valor no seu sinal de saída, mas esse valor tem que estar dentro da faixa de operação. Servem para medir grandezas que podem assumir qualquer valor ao longo do tempo, como: pressão, temperatura, velocidade, umidade, vazão, torque, entre outras. Já os sensores digitais podem assumir apenas dois valores no seu sinal de saída, zero ou um. Mas grandezas físicas não assumem apenas zero ou um de forma natural, logo, o sinal deve ser convertido pelo circuito eletrônico do transdutor e posteriormente, enviados ao sistema de controle como um sinal digital (THOMAZINI; ALBUQUERQUE, 2005).



**Figura 1. Funcionamento de Um Sensor**

**Fonte: Adaptado de THOMAZINI; ALBUQUERQUE, 2005**

### 2.3. Transdutor

Transdutor é um dispositivo completo, que possui um sensor, e é utilizado para realizar a conversão de uma grandeza qualquer em outra para que possa ser utilizada nos dispositivos de controle. Ele pode ser considerado como sendo uma interface entre a energia existente no ambiente e o circuito de controle ou interface entre controlador e atuador. Os transdutores possuem a capacidade de transformar uma variável física em um sinal de tensão ou corrente que poderá ser lida e interpretada, de maneira simples, por um sistema de controle (THOMAZINI; ALBUQUERQUE 2005).

O transdutor converte energia de um domínio para outro, calibrado para minimizar a erros no processo de conversão. Um sensor é um dispositivo que fornece uma saída útil para um mensurando especificado. O sensor é um elemento básico de um transdutor, mas também pode ser um detector de tensão ou corrente no regime elétrico, o que não requer conversão (WRIGHT, 1993). As medições mecânicas que requerem um transdutor para fornecer uma saída elétrica estão listadas na Tabela 1.

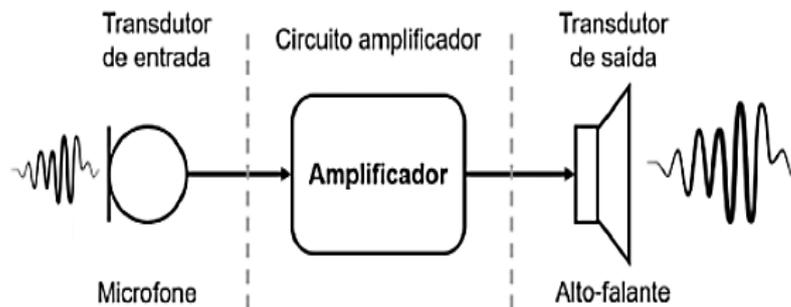
**Tabela 1. Medidas Mecânicas**

**Fonte: Adaptado de FRANKY, 2000**

<b>Medida</b>	<b>Técnicas Típicas / Comuns</b>
Deslocamento / posição	Relutância Variável, efeito Hall, opto-eletrônico
Temperatura	Termistor, tensão base-emissor de transistor
Pressão	Piezo resistivo, capacitivo
Velocidade (linear/angular)	Relutância variável, efeito Hall, opto-eletrônico
Aceleração	Piezo resistivo, capacitivo, piezo eletrônico
Força	Piezo resistivo
Torque	Opto eletrônico
Impedância Mecânica	Piezo resistivo
Tensão	Piezo resistivo
Fluxo	Pressão Delta
Umidade	Resistivo, capacitivo
Proximidade	Ultrassônico

Alcance	Radar
Nível de Líquido	Ultrassônico
Erro	Torque duplo
Colisão Iminente	Radar

Há uma distinção entre transdutor de entrada (sinal físico/ sinal elétrico) utilizados para detectar sinais e transdutor de saída (sinal elétrico/ display ou atuador) utilizados para gerar movimentos mecânicos ou executar uma ação. Por exemplo em um sistema de amplificação de áudio, em que o transdutor de entrada, o microfone, que converte o som em um sinal elétrico, o qual é amplificado por um circuito de amplificação e, em seguida, o sinal elétrico é novamente convertido em som pelo alto-falante, o transdutor de saída. Como esquematizado na Figura 2.



**Figura 2- Funcionamento de um transdutor**

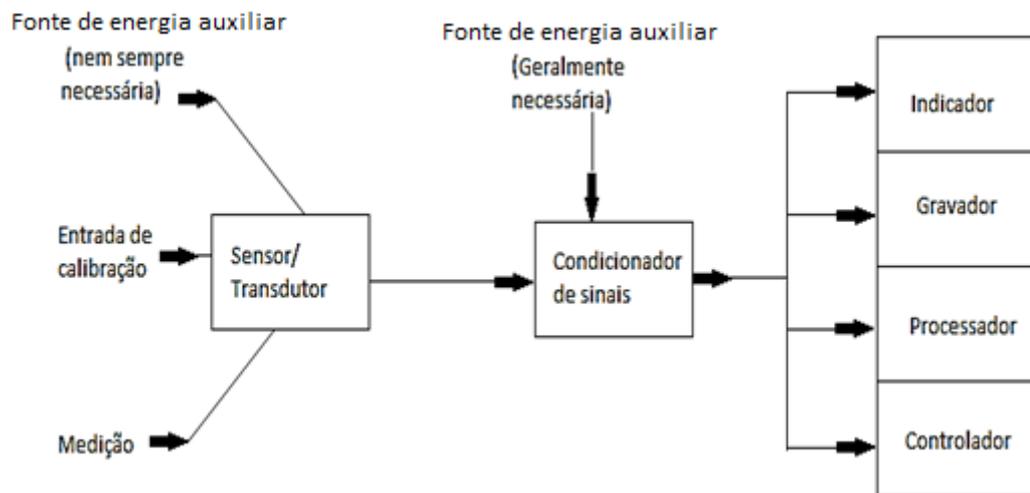
**Fonte: FRANK, 2000**

Um transdutor pode estar compreendido em dois ou mais estágios. O primeiro estágio faz a conversão dos parâmetros físicos em outros parâmetros físicos mensuráveis de um jeito mais fácil, já os estágios subsequentes fazem a conversão desses parâmetros físicos em parâmetros elétricos. O estágio primário é o sensor e o secundário o transdutor. Um sensor é único, já o transdutor é composto. Os transdutores estão em contínua melhora, vindo com várias vantagens adicionais, uma delas é a inteligência (BHUYAN,2013).

#### **2.4. Sensor Inteligente**

De acordo com (FRANKY, 2000) o termo sensor inteligente foi criado em meados da década de 1980, e desde então vários dispositivos têm sido chamados de sensores inteligentes.

A inteligência desses dispositivos está na unidade microcontroladora (MCU), processador de sinais (DSP) e tecnologias de circuitos integrados específicos de aplicativos (ASIC) desenvolvido por vários fabricantes de semicondutores. O termo sistema microeletromecânico (MEMS) é usado para descrever uma estrutura criada com processos de fabricação de semicondutores para sensores e atuadores. Antes da disponibilidade da microeletrônica, os sensores ou transdutores usados para medir grandezas físicas, como temperatura, pressão e fluxo, geralmente eram acoplados diretamente a um dispositivo de leitura, que é lido por um observador. O transdutor converte a grandeza física medida em um deslocamento. O observador então, inicia as correções do sistema para alterar a leitura mais perto de um valor desejado. Os blocos típicos de um sistema de medição estão mostrados na Figura 3.



**Figura 3. Típico Sistema de Medição**

**Fonte: Adaptado de FRANKY, 2000**

O avanço da tecnologia de microprocessadores, exigiu que os sensores tivessem uma saída elétrica que pudesse ser prontamente interfaceada para fornecer medições autônomas ao controle. Isso também exigiu que o nível do sinal analógico fosse amplificado e convertido para o formato digital antes de ser fornecido ao controlador de processo.

A definição de sensor inteligente (transdutor inteligente) não foi tão amplamente aceita e está sujeita ao uso indevido. No entanto, o Instituto de Engenheiros Eletricistas e Eletrônicos (IEEE) vem se consolidando ativamente na terminologia que se aplica aos sensores microeletrônicos. O IEEE 1451.2 define um sensor inteligente como um sensor que fornece funções além daquelas necessárias para gerar uma representação correta de uma quantidade

detectada ou controlada. Esta função tipicamente simplifica a integração do transdutor em aplicações em um ambiente de rede. Essa definição fornece um ponto de partida para o conteúdo mínimo de um sensor inteligente. Os sensores inteligentes futuros serão capazes de muito mais e classificações adicionais podem ser necessárias para diferenciar os produtos.

Segundo (CORSI, 2006) o termo "*Smart Sensors*" refere-se a sensores que contêm capacidades de processamento de sinal e objetivos que variam desde a visualização simples para um sofisticado sensoriamento remoto, vigilância, pesquisa / rastreamento, orientação de armas, robótica e aplicações de inteligência. Recentemente esta abordagem está atingindo metas mais altas por um conceito novo e revolucionário sobre sensores, introduziu a eles algumas das funções básicas dos olhos vivos, como o olhar dinâmico, compensação de não-uniformidade, filtragem espacial e temporal.

A saída dos sensores é a única fonte de dados para a tomada de decisão, é muito importante conhecer o estado de funcionamento destes sensores. Os sensores inteligentes têm a capacidade de alertar o controlador a ocorrência de falhas na conexão, quedas de tensão nos terminais ou aumento da temperatura ambiente, mas não conseguem alertar a quando ocorre uma degradação física, o que pode gerar medições inexatas na grandeza medida. Deve-se levar em conta os problemas de validação e substituição do sensor com falha para realizar de um projeto moderno de monitoramento, de diagnóstico, ou de sistemas de controle (Tian et al., 2000).

Segundo (BHUYAN, 2013) um sensor inteligente é aquele que possui uma unidade integrada de processamento de sinal que atinja versatilidades maiores. Eles podem executar desde operações mais simples a operações complexas utilizando algoritmo de linearização de calibração.

## **2.5. Sensores Autovalidantes**

A necessidade de validar a saída do sensor e dar a confiabilidade ao valor medido, uniu as universidades Oxford e a Foxboro em 1988 e, em 1993, dois professores da Universidade de Oxford, Henry e Clarke, apresentaram o conceito de sensor SEVA e propuseram a teoria e o modelo correspondente. (HENRY e CLARKE, 1993; HENRY, 1994, 1996).

O SEVA é uma nova geração de sensores, que possuem componentes a mais que o sensor tradicional, e são usados para implementar o diagnóstico de falhas, a recuperação de dados e gerar parâmetros do SEVA. É um sistema de sensor integrado que incorpora software, hardware e análise. Desde 1993, pesquisadores e empresas se concentraram nessa pesquisa. Até

agora, o desenvolvimento do sensor SEVA passou por três etapas e um padrão comum BS-7986 baseado em conceitos, o SEVA foi desenvolvido pelo British Standards Institute, que descreveu o diagnóstico do sensor e a qualidade da medição (FENG et al., 2007).

Em sistemas tradicionais de monitoramento e diagnóstico de falhas utiliza-se a chamada redundância por hardware, em que mais de um sensor realiza uma mesma medida. Embora esta técnica seja ainda utilizada por apresentar resultados confiáveis (THEILLIOL et al., 2002), ela apresenta algumas desvantagens, tais como o custo elevado de aquisição de um maior número de sensores ou a disponibilidade de espaço requerido para a instalação dos mesmos. Há também a chamada redundância por software, que faz uso da estimativa dos sinais por meio de um modelo matemático. Esta metodologia tem a principal vantagem de não implicar em um acréscimo de componentes ao sistema existente, reduzindo os custos e minimizando o espaço de instalação.

Segundo (NICOLA et al., 2006 apud FENG et al., 2004) os padrões IEEE 1451 tem como objetivo definir um conjunto de interfaces comuns para conectar transdutores a sistemas baseados em microprocessadores, instrumentos e redes de campo de maneira independente da rede; permitir que os transdutores sejam substituídos e / ou removidos com o mínimo de esforço; eliminar etapas de configuração manuais do sistema, propensas a erros; possuir suporte a dados gerais de transdutores, controle, temporização, configuração e modelo de calibração; e o desenvolvimento de folhas de dados eletrônicas de transdutores (TEDS) que permanecem com o transdutor durante a operação normal. A ênfase destes padrões é uma interface comum.

### **3. Métodos de Autovalidação**

De acordo com (BHUYAN, 2013), a função de autovalidação tem duas classificações, a validação funcional e a validação tecnológica. Abaixo estão apresentados o conceito dessas duas classificações e alguns modelos de autovalidação.

#### **3.2. Validação Funcional**

De acordo com (BHUYAN, 2013), a validação funcional tem a função de detectar a consistência da medida ou da estimativa produzida pelo sensor ou um recurso utilizado pelo algoritmo de estimação. O sistema deve ser capaz de detectar a falha e isolá-la. As técnicas numéricas de detecção de falhas do sensor se baseiam no processamento de sinais do sensor que visa uma estimativa do estado, estimativa de parâmetro, filtragem adaptativa, lógica de limiar variável, teoria da decisão estatística e conceitos de redundância analítica, todas elas dependem da modelagem matemática do sistema.

##### **3.2.2. Métodos Numéricos**

Deve-se desenvolver um modelo de falha do sistema do sensor inteligente para que se possa estimar as falhas e isolamento dos sensores.

- **Modelo de Falhas com Base na Alteração da Distribuição:** Uma falha no sensor local desenvolve um sinal determinístico dando a saída do sensor local.
- **Modelo de Falhas com Base na Estimativa de Dados Locais:** A autovalidação se baseia em detectar as falhas através de resíduos em estado normal.

##### **3.2.3. Inteligência Artificial para Validação de Sensor**

A inteligência artificial é uma associação importante aos sensores nos casos onde as medidas confiáveis são muito complicadas ou onde não existem modelos matemáticos válidos, como em plantas complexas, variantes no tempo e não lineares. Há duas formas de aplicação da inteligência artificial, uma delas são os sistemas especialistas e a outra as redes neurais artificiais. O sistema especialista age como o raciocínio humano para a resolução de problemas, faz cálculos numéricos ou processamento de dados. Através de conhecimento heurístico o raciocínio é formado. As abordagens de sistemas especialistas têm mudado seu raciocínio de forma gradual, saindo das abordagens baseadas em regras usando o raciocínio empírico para abordagens baseadas em modelos usando o raciocínio funcional. Usando o conhecimento sobre a estrutura, as funções e o comportamento do sistema, é possível realizar o diagnóstico com

base em modelo, e como vantagem não necessitar de experiência de campo, é flexível a possíveis mudanças no projeto e redução na quantidade de experiências realizadas. (BHUYAN, 2013).

#### **3.2.4. Abordagem Baseada em Modelo**

De acordo com (BHUYAN, 2013) a abordagem baseada em modelo possui o conhecimento especializado dentro de um modelo no domínio especialista. Estes modelos são empregados quando se deseja uma simulação para explorar as condições de falhas hipotéticas.

#### **3.2.5. Abordagem Baseada em Redes Neurais**

A inclusão da inteligência artificial em um sistema é capaz de trazer melhorias ao desempenho, confiabilidade e robustez do controle, pelo fato de agregar um tipo de conhecimento que não seria resgatado nos modelos analíticos tradicionais (DRIANKOV et al., 1996 apud PEREIRA 2006).

O uso das redes neurais é empregado para que se possa aproveitar a sua capacidade de aprendizado e aproximação de funções (HASSOUN, 1996 apud PEREIRA 2006), de uma maneira que elas aprendam a curva de calibração do sensor com o tempo. Depois que se conhece o padrão e variação curva, tem-se a possibilidade de correção dos erros causados pela descalibração e mostrar quando o sensor não está calibrado (PEREIRA, 2006).

Segundo (BHUYAN, 2013), as redes neurais têm boa aplicabilidade na validação e detecção de falhas de sensores por ter a capacidade de reconhecer padrões. Em condições de falha, a rede é treinada usando os dados medidos pelo sensor, podendo assim fazer uma distinção de uma medida normal e uma com defeito. A maior vantagem das redes neurais é que um modelo aproximado consegue mapear a relação funcional do sensor e como desvantagem do seu uso está a necessidade de dados de medida de alta precisão para validação on-line; a rede se forma em forma de peso, o que causa dificuldade de compreensão, e a incapacidade de raciocínio.

Segundo (HAYKIN, 2001), as redes neurais possuem várias características que fazem do seu uso relevante, tais como:

**Aprendizado:** Elas possuem capacidade de aprendizado. O aprendizado pode ser de dois tipos, o aprendizado supervisionado e o não-supervisionado.

**Não-linearidade:** Podem ter comportamento linear ou não. Quando os sinais de entrada da rede não forem lineares, como acontece na maior parte dos processos naturais, ela é capaz de fazer a modelagem desses sistemas de maneira automática.

**Capacidade de decisão sobre a qualidade da informação:** Ela pode decidir qual a resposta correta e também avaliar a qualidade da decisão.

**Adaptabilidade:** Possuem alta capacidade de adaptação às mudanças ambientais.

**Informação contextual:** O que um neurônio faz, afeta todos os outros, fazendo com que o conhecimento adquirido pela rede seja refletido dentro da sua própria estrutura.

**Tolerância a falhas:** Por possuir uma estrutura robusta, elas conseguem tolerar falhas porque a sua degradação se dá de forma suave mesmo em condições adversas.

**Implementação em VLSI:** Devido a sua natureza paralela, elas são muito indicadas para implementação usando a tecnologia de integração em larga escala.

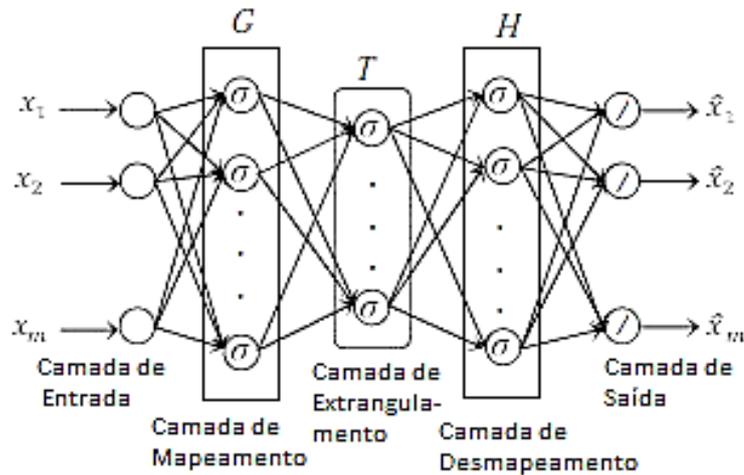
Para (BHUYAN, 2013), uma coisa relevante relacionada a detecção de falhas baseadas nas redes neurais é a geração de dados referentes às medidas feitas pelo sensor em boas condições e de sensores com defeito. Nesse método para os vetores de entradas medidas pelo sensor, existirá um conjunto definido de vetores de saída estimadas pelo sensor. Outra coisa relevante também, é o treinamento de rede, onde os vetores de entrada são aplicados à rede com vetores específicos de saída e os pesos da rede vão se atualizando enquanto são treinadas.

E por último e não menos importante está o teste da rede com vetores de medidas de teste e a geração de resíduos. Os resíduos são as diferenças resultantes das saídas reais medidas em uma planta e as estimativas das saídas da rede neural. Quando uma planta não é fácil de modelar por causa das suas complexidades e quando ela não é linear, a rede tem a capacidade de representar um modelo baseado em conhecimento.

### 3.2.6. Abordagem Baseada em Redes Neurais Auto-Associativas

A inspiração das redes neurais auto-associativas vem da metodologia NLPCA (*nonlinear principal components analysis*) (COURA et al., 2004 apud SÁNCHEZ, 2011). Nesta metodologia, as informações de entrada de um dado sistema são mapeadas na saída a partir de uma função  $G$ , não linear. As informações originais são construídas através de um “desmapeamento”, expresso por uma função  $H$ , também não linear. As funções  $G$  e  $H$  são escolhidas de forma a se minimizar a perda de informação no processo mapeamento-desmapeamento (TANSCHKEIT et al., 2012 apud SÁNCHEZ, 2011). Na arquitetura em questão,

faz-se uso de duas redes neurais conectadas em série, responsáveis pela implementação do mapeamento, G, e do desmapeamento, H, dos sinais, conforme mostrado na Figura 4.



**Figura 4- Rede neural auto-associativa**

**Fonte: Adaptada de SÁNCHEZ et al., 2001**

As modelagens de monitoramento podem estar em duas grandes categorias: as redundantes e as não redundantes. No modelo redundante, um conjunto de sensores realiza uma verificação do funcionamento de um mesmo processo. Para se obter o resultado, pode-se utilizar a média das leituras dos vários sensores. Em contraste, as técnicas de modelagem não redundantes se baseiam na estimação das medidas de instrumentos correlacionados (HINES e GARVEY, 2007).

Nos modelos não redundantes, deve-se dar muita importância para a seleção dos sensores que serão incluídos como entrada. Os modelos construídos com grupos de sensores cujos dados medidos apresentam correlações altas geram menor erro de predição quando comparados com os modelos que apresentam uma baixa correlação nos vetores de entrada (HINES et al., 2000; NAJAFI et al., 2004; KRAMER, 1991).

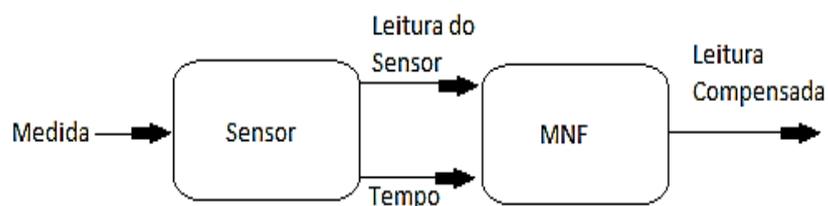
Um vetor de entrada da rede,  $X$  é formado com as medidas dos sensores. Correspondente à dimensão do vetor de medidas está a dimensão  $m$  da camada de entrada. A camada de saída realiza a produção do vetor de dados reconstruído, com a mesma dimensão da camada de entrada. A camada de mapeamento G, contém um número de neurônios maior do que número de entradas. A camada de estrangulamento (bottleneck) T, possui dimensão inferior à da camada de entrada. A camada de desmapeamento H, possui dimensão igual à da camada de mapeamento. A camada T é a projeção do vetor de entrada no espaço de características. Nesta

rede, os pesos são atualizados para cada amostra, de forma que, ao final do processo, a distribuição dos pesos possa caracterizar a rede neural como uma matriz identidade. Que quer dizer que se tem o objetivo de otimizar a topologia da rede de forma a reconstruir as  $m$  variáveis de entrada com o menor erro possível, utilizando-se para tal um conjunto reduzido de neurônios na camada de estrangulamento.

A camada de estrangulamento força uma codificação e compressão das entradas, com uma posterior descodificação ou descompressão. Eventuais correlações ocultas existentes nos dados serão capturadas pela camada de estrangulamento e os efeitos de não correlação – produzidos, por exemplo, por ruído nos sinais – serão excluídos nesta camada (KRAMER, 1991). Quando a rede é treinada com dados adequados, a saída para um novo dado da mesma distribuição do conjunto de treinamento estará o mais próximo possível do estado livre de ruído.

### 3.2.7. Modelo Neuro-Fuzzy (MNF)

A compensação realizada a partir de um modelo neuro-fuzzy é do tipo não linear que faz a correção das medidas que são alteradas pelo desgaste do sensor ao longo da sua vida. O algoritmo faz com que o instrumento possa ficar ativo por mais tempo no processo, evitando sua retirada da linha de produção para possíveis manutenções em laboratório. O funcionamento do modelo neuro-fuzzy (MNF) vem do princípio de que ele receberá os valores medidos de um sensor de campo e o seu tempo de funcionamento, gerando, na saída, a medida equivalente de um sensor calibrado (PEREIRA et. al., 2004), como mostra a Figura 5.

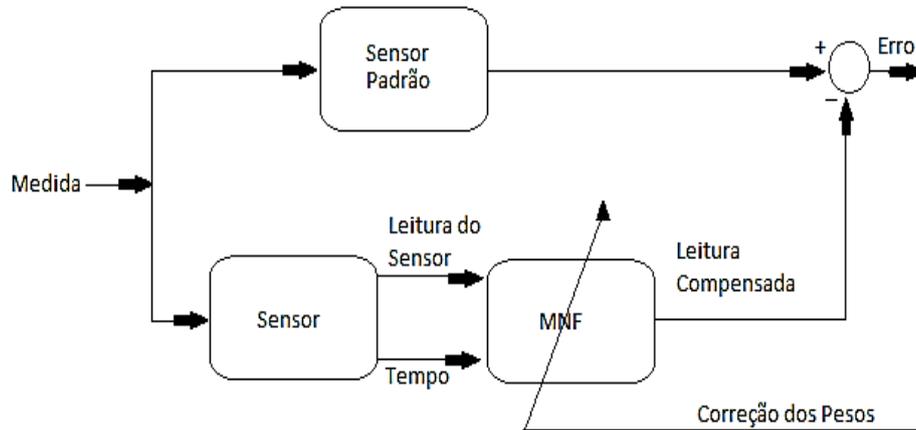


**Figura 5- Compensação do sensor inteligente**

**Fonte: Adaptada de SÁNCHEZ et al., 2010**

Segundo (SÁNCHEZ et al., 2010) o sinal de medição chega ao sensor, e é processado para retornar uma resposta que equivale ao sinal lido em voltagem ou corrente, mas isso depende do tipo de condicionamento do sinal que será utilizado. A entrada do MNF são as informações fornecidas junto com o tempo de funcionamento do sensor, ela retorna em sua saída a leitura do sensor compensado. O modelo neuro-fuzzy realiza o ajuste de seus parâmetros

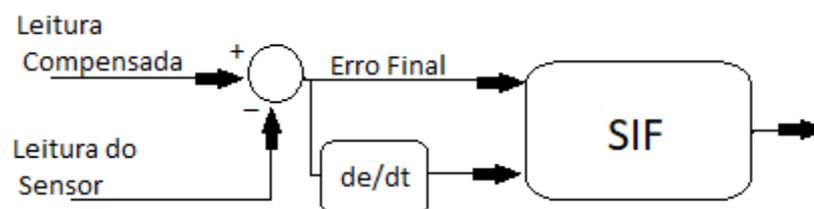
em função do erro gerado pela diferença das medições do sensor padrão e a leitura compensada da rede, buscando uma saída final igual à de um instrumento calibrado. O treinamento do modelo neuro-fuzzy para a auto-compensação está representada na Figura 6.



**Figura 6- Treinamento do MNF**

Fonte : Adaptada de SÁNCHEZ at al., 2010

O modelo proposto tem como base um Sistema de Inferência Fuzzy (SIF) do tipo Mamdani com o objetivo de estabelecer a confiabilidade dos dados medidos pelo instrumento. A auto-validação dos dados que o sensor gera, é calculado baseando-se na diferença do sinal compensado e o sinal medido pelo sensor, fazendo com que no final se tenha um erro que pode variar no tempo. Assim, as entradas do sistema são o erro e a taxa de variação. A modelagem do sistema de auto-validação está representada na Figura 7.

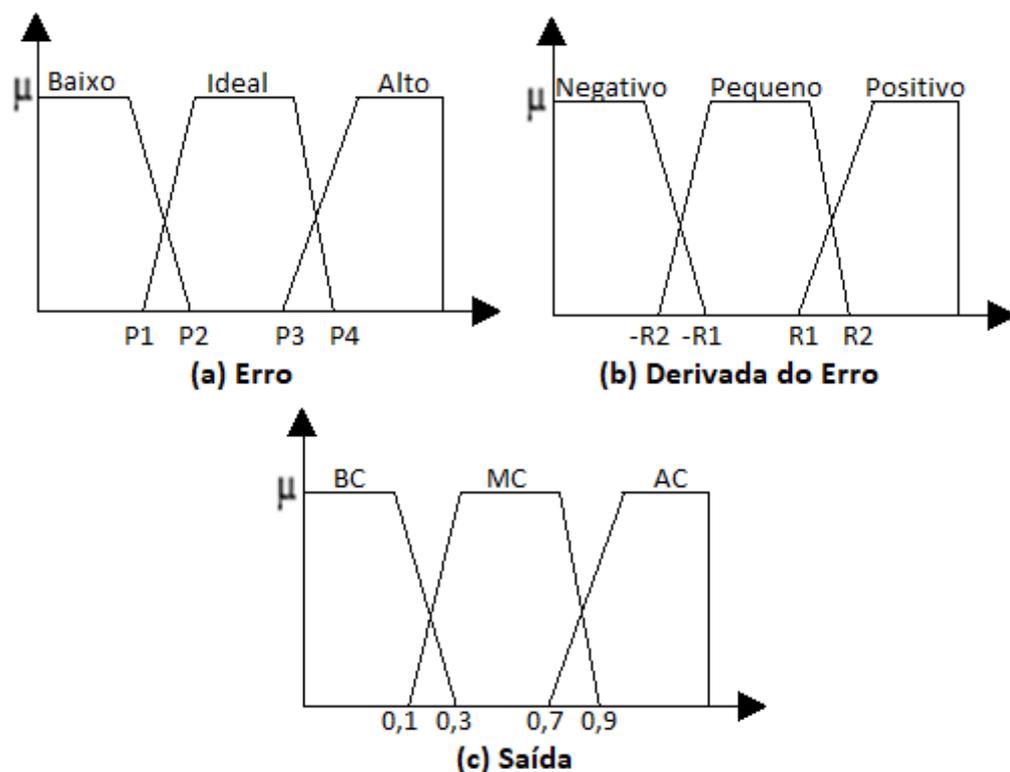


**Figura 7- Modelagem do sistema de auto-validação**

Fonte: Adaptada de SÁNCHEZ at al., 2010

Cada variável de entrada possui três conjuntos fuzzy associados, e são definidos pelas funções de pertinência apresentadas na Figura 8. Para cada um dos sensores, os parâmetros P1,

P2, P3, P4, R1 e R2 devem ser especificados. A Figura 8a faz uma descrição das funções de pertinência do erro, ou seja, a diferença dos valores processados pelo sensor que não está calibrado e os valores compensados. Os dados que estão dentro do intervalo ideal têm uma alta confiabilidade, já os dados que estão fora deste intervalo têm baixa confiabilidade. A Figura 8b descreve a derivada do erro que analisa a taxa de variação da diferença entre a medida feita pelo sensor descalibrado e os valores compensados com o tempo. Dados com altas taxas de variação apresentam baixa confiabilidade, o que não desejável em um processo. Os termos linguísticos e as respectivas funções de pertinência associadas à variável de saída do sistema de inferência fuzzy estão representadas na Figura 8c. A partir do método do Centro de Gravidade (COG), a saída defuzzificada, é calculada para estimar o grau de confiabilidade das medidas do sensor. Esta saída é classificada em três intervalos de confiabilidade. Valores inferiores a 0,3 serão qualificados como de baixa confiabilidade (BC). Saídas entre 0,3 e 0,7 são qualificados como de média confiabilidade (MC), enquanto que saídas maiores do que 0,7 serão qualificadas como de alta confiabilidade (AC).



**Figura 8- Funções de pertinência das entrada**  
**Fonte: Adaptado de SÁNCHEZ at al., 2010**

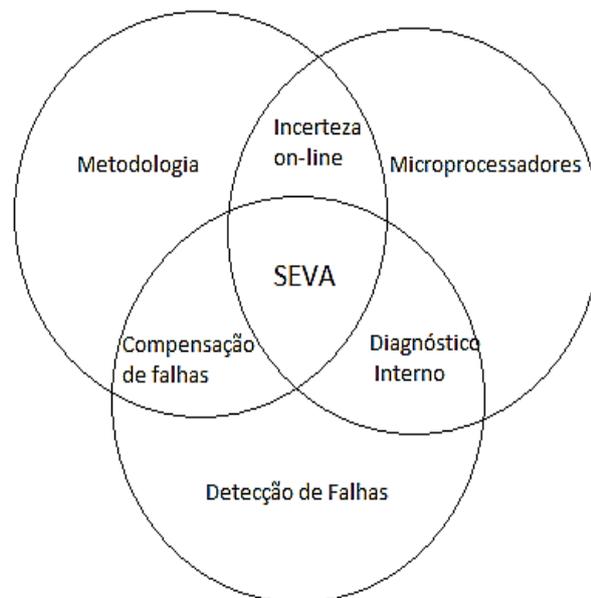
### 3.3. Validação Tecnológica

Segundo (BHUYAN, 2013), existem um grande número de técnicas de autovalidação de sensores que utiliza tecnologia de sensores

### 3.3.2. Modelo SEVA

O sensor SEVA se difere do sensor tradicional por possuir o poder de estimar a precisão da medição enquanto implementa a função comum para saída do valor medido. Ele pode diagnosticar a si mesmo na ocorrência de uma falha, detectando a falha do sensor, analisando o modo de falha e criando a melhor estimativa para a saída, substituindo a medição defeituosa (FENG at al., 2007).

A tecnologia de sensores SEVA pode ser vista como uma combinação de tecnologias como está representada pela interseção dos círculos na Figura 9.



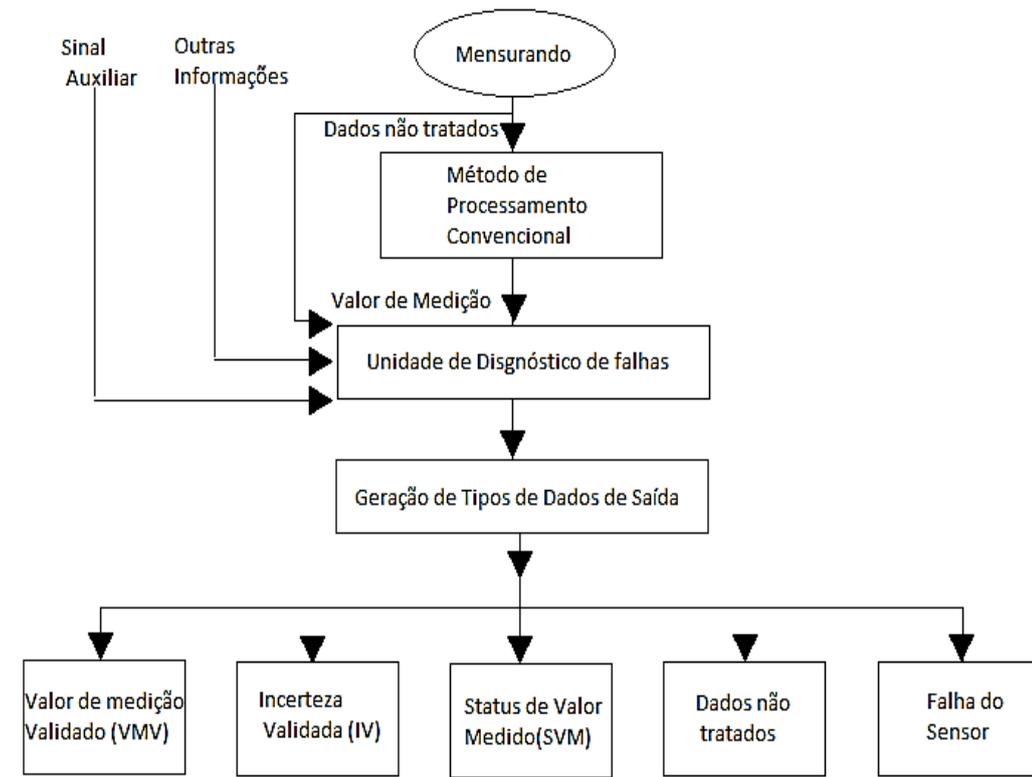
**Figura 9- Tecnologia do sensor SEVA**

**Fonte: Adaptado de FENG at al., 2007**

O sensor SEVA é um tipo de sensor, que não apenas produz o valor de medição, mas também estima seu desempenho e estado. A figura 10 mostra a arquitetura da função do sensor SEVA.

Segundo (BHUYAN, 2013) as principais características do modelo SEVA são:

- Ele detecta as falhas internamente a partir do conhecimento do fabricante do sensor;
- É possível que a cada medida tenha um impacto individual de cada falha;
- Possui um microcontrolador embutido que realiza o autodiagnóstico e correção das medidas.



**Figura 10- Arquitetura do sensor SEVA**  
**Fonte: Adaptado de FENG et al., 2007**

## 4. SEVA

### 4.1. Parâmetros de saída do sensor SEVA

De acordo com (BHUYAN, 2013), independentemente do dispositivo usado, o modelo SEVA gera alguns parâmetros de saída:

- **O valor da Medida Validado (VMV):** É a medida estimada mais próxima do valor da medida atual. Corresponde à medição convencional, mas na ocorrência de uma falha, a VMV é uma melhor estimativa corrigida do valor real do valor medido. O VMV é estimado da seguinte maneira:

- Na ocorrência de uma falha menor: é aplicada uma correção para corrigir a medida.

- Na ocorrência de uma falha grave: a medida é estimada baseada em dados históricos armazenados em uma EPROM do microprocessador.

- **A Incerteza Validada (IV):** É o índice de validade gerado com cada VMV. Esta é a incerteza da medida, ou provavelmente erro do VMV. A incerteza é o desvio de uma medida a partir do valor médio do conjunto de dados expressos como porcentagem. Para calcular a incerteza, o microcontrolador executa um cálculo a cada dado medido.

- **O Status de Valor Medido (SVM):** É um índice de validade da medida que indica a fonte de precisão ou de incerteza. Através de um código discreto, disponível na tabela 2, pode-se obter o status.

- O status do dispositivo: É um valor discreto que faz um resumo da saúde do sensor, muito usado nas manutenções do sensor. Gera para cada valor medido um parâmetro, ele pode ser:

- BOM: Quando não há falha no sensor.

- TESTE: Quando a detecção de falhas está sendo realizada pelo sistema inteligente e essa pode ter perda da qualidade medida.

- SUSPEITO: Quando o sensor pode ter sofrido uma falha, que não foi diagnosticada ainda.

- DEFICIENTE: Quando existe uma falha já diagnosticada, necessita de um reparo/manutenção de baixa prioridade.

- MAU: Quando existe uma falha já diagnosticada, necessita de um reparo/manutenção de alta prioridade.

- CRÍTICO: Quando a condição do sensor é crítica, necessita de atenção imediata.

Como o sensor SEVA disponibiliza mais dados e parâmetros, através de muita análise e cálculo, que os sensores tradicionais, sua arquitetura é muito mais complexa do que os

sensores inteligentes tradicionais. Logo, o sensor SEVA deve satisfazer alguns padrões, descritos abaixo (FENG et al., 2007):

*Tabela 2- Parâmetro de Status*

Parâmetro de Status	Condições do Sensor	Métodos de Estimação VMV	Correção	Status UV
CLARO	Sem falha	Dados atuais	Não	Nulo
TURVO	Falha parcial	Técnica de compensação	Não	Aumentado
CEGO	Falha severa	Dados históricos		
OFUSCADO	Possivelmente temporária, mas severa	Dados históricos		
SEGURO	Falha e não usado	Sensor virtual redundante		
INVÁLIDO	Falha e não usado	Validação não operacional		

- Capacidade de cálculo – Possui a capacidade de realizar cálculos para medição, diagnóstico de falhas online, reconstrução de dados e análise de IV. O sensor SEVA deve lidar com essas tarefas em tempo real.
- Capacidade de comunicação - Pode se comunicar facilmente com sistema de controle industrial por barramento de campo ou rede ethernet. Comparado ao sensor tradicional, ele leva vantagem, pois o tradicional apenas fornece ao centro de controle o valor analógico da medição. Com isso, entre o sensor e o centro só há uma direção de sinal do sensor para o centro, já o sinal entre o sensor SEVA e o centro é uma mistura bidirecional de sinais digitais e analógicos, que requer a capacidade de se conectar facilmente com o sistema de controle industrial por barramento de campo ou rede ethernet.
- Plasticidade e flexibilidade - O sensor SEVA tem aplicabilidade em outras situações, onde a arquitetura de hardware deve ser modular com plasticidade e flexibilidade, além

de realizar as funções básicas acima, e a plasticidade permitirá que ele incorpore outros sensores para formar o novo sensor SEVA.

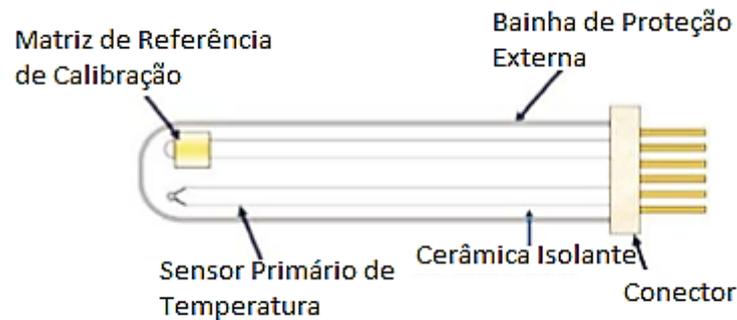
- Eficiência de custo e baixo volume - Embora o sensor SEVA tenha muitas vantagens sobre os sensores tradicionais, a complexidade da arquitetura de hardware, a fabricação de custo de desenvolvimento será muito mais do que os tradicionais. A fim de substituir os sensores tradicionais pelo sensor SEVA em aplicações de todos os aspectos, menores custos de fabricação e baixo volume são propriedades necessárias para a comercialização do sensor SEVA enquanto competem com os sensores tradicionais.

#### **4.2. Desenvolvimento de pesquisa de diagnóstico de falha de sensor e reconstrução de sinal e algumas aplicações**

Segundo (FENG et al., 2007), os pesquisadores deram ênfase em pesquisas de diagnóstico de falhas de sensores e reconstrução de sinais e também em projeto de estrutura de hardware e software do sensor SEVA. O desenvolvimento da pesquisa do sensor SEVA será apresentado de acordo com esses dois aspectos.

A partir de 1993, para o desenvolvimento de pesquisa de diagnóstico de falha de sensor e reconstrução de sinal, os pesquisadores propuseram uma série de métodos para diagnóstico de falhas, que são descritos como as seguintes categorias:

- a) Redundância de hardware - No método de redundância de hardware, mais de um sensor é usado para medir o mesmo parâmetro, comparando a saída desses sensores, o sensor com falha pode ser determinado. Este método possui vantagens como, fácil implementação e alta confiabilidade. Sua desvantagem é o alto custo de manutenção. Barberree (2002, 2003) desenvolveu um sensor de temperatura autovalidante, que possui uma sonda com uma unidade inteligente chamada Matriz de Referência de Calibração para fornecer informações seguras, de aviso e falhas do sensor (BARBERREE, 2002, 2003 apud FENG et al., 2007). A representação da Matriz de Referência de Calibração do Sensor (CRM) na ponta da sonda está na Figura 11. O sensor primário é na verdade uma parte do CRM. O CRM é uma combinação de materiais termicamente sensíveis ou elementos térmicos escolhidos para que possam gerar múltiplos sinais independentes representando a temperatura na ponta da sonda e também fornecer monitoramento das condições de cada elemento.



**Figura 11-Matriz de Referência de Calibração do Sensor**

**Fonte: Adaptado de BARBERREE, 2002**

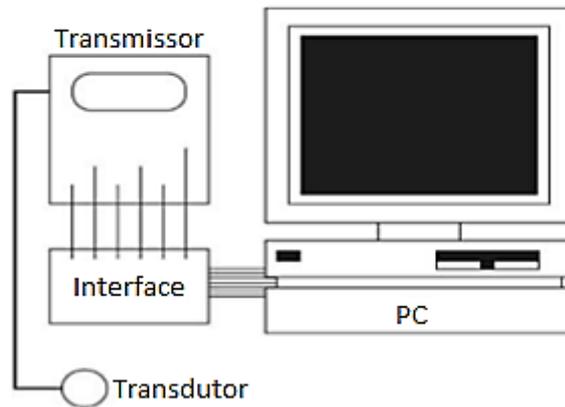
- b) Redundância analítica - No método de redundância analítica, a relação entre multisensores ou o modelo matemático é usada para diagnosticar a falha do sensor e reconstruir o sinal de falha.
- c) Redundância analítica multisensor - No método de redundância analítica multisensor está inclusa a análise de componentes principais (PCA), redes neurais artificiais e método de lógica difusa. Com a PCA, Wang e Chen, em 2004, detectaram, diagnosticaram e reconstruíram sensores defeituosos dos sistemas centrais de refrigeração do edifício (WANG e CHEN, 2004 apud FENG et al., 2007 apud FENG, 2007). Joe S. Qin propôs uma abordagem de sensor inferencial de auto-validação com base na análise de componentes principais, e a aplicou no monitoramento de emissões atmosféricas (JOE et al., 1997 apud FENG et al., 2007). Na pesquisa do medidor de fluxo de coriolis digital SEVA, Liu et al. (2001) usaram a rede neural para corrigir a medição do fluxo de massa para efeitos de fluxos bifásicos, baseados inteiramente em parâmetros observados internamente, mantendo os erros dentro de 2% (LIU et al., 2001 apud FENG et al., 2007). Frolik e Abdelrahman (2001, 2000) desenvolveram suas pesquisas sobre as relações lineares aproximadas dos sensores com as regras da lógica difusa para a auto-validação e autoconfiança. Eles usaram para reconstruir aqueles dados perdidos e aqueles com baixa confiança. E esses dados são fundidos para determinar uma medida única e sua confiança (FROLIKE ABDELRAHMAN, 2001, 2000; ABDELRAHMAN e KANDASAMY, 2000 apud FENG et al., 2007). PhaniShankar et al. (2000) desenvolveram algoritmos de auto-validação baseados em funções-membro para descrever as regras da lógica fuzzy. A confiança de medição foi alcançada por essas funções de membro. E essa metodologia foi ilustrada pelos

dados de temperatura do forno de fusão de ferro (PHANISHANKAR et al., 2000 apud FENG et al., 2007).

- d) Redundância analítica baseada em modelo matemático - Clarke e Fraher implementaram um sensor SEVA DO<sub>x</sub>, no qual um procedimento de teste, baseado em um modelo físico dos processos de difusão no sensor, fornece detecção de falhas e capacidade de correção (CLARKE e FRAHER, 1996 apud FENG et al., 2007).
- e) Método de análise - Wavelet Zhang propôs uma nova abordagem baseada em transformadas wavelet para validação de sensor (MA et al., 1999; ZHANG et al., 2000; ZHANG, 2001a, b, c apud FENG et al., 2007). Por meio de transformadas wavelet que localizam bem a caracterização de um sinal nos domínios de tempo e frequência, os instantes ocorrentes de status anormal de um sensor em seu sinal de saída podem ser identificados. Em seguida, as distribuições de energia de sinal, em todos os níveis de wavelets decompostos desse sinal antes e depois desses instantes, são usadas para validar o status do sensor.

Moran desenvolveu outro método com três algoritmos de auto validação, a Aproximação Estocástica (SA), a Estimativa de Polarização Reduzida (RBE) e o Mapa Bayesiano de Auto-Organização usando Kernels Gaussianos (GK). Estudos de simulação mostraram que o método baseado em GK deu resultados superiores quando comparado ao algoritmo RBE. Também foi demonstrado que o método GK era mais computacionalmente eficiente e requer espaço de armazenamento para menos variáveis. As técnicas são demonstradas usando dados de um sensor de termopar (MORAN et al., 2001 apud FENG et al., 2007).

Desde quando foi apresentado por Henry e Clarke o conceito de sensor SEVA, muitos pesquisadores e empresas se concentraram nesse campo. Atualmente, o desenvolvimento do sensor SEVA passou por alguns passos. O PC + cartão de amostragem de dados é a arquitetura do sensor SEVA de primeira geração. Com este programa de designers de plataforma de hardware para implementar a função do sensor SEVA no PC. A Figura 12, mostra modelo típico de hardware usado na primeira geração do sensor SEVA.



**Figura 12- Hardware da Primeira Geração do Sensor SEVA.**

**Fonte: Adaptada de FENG et al., 2003**

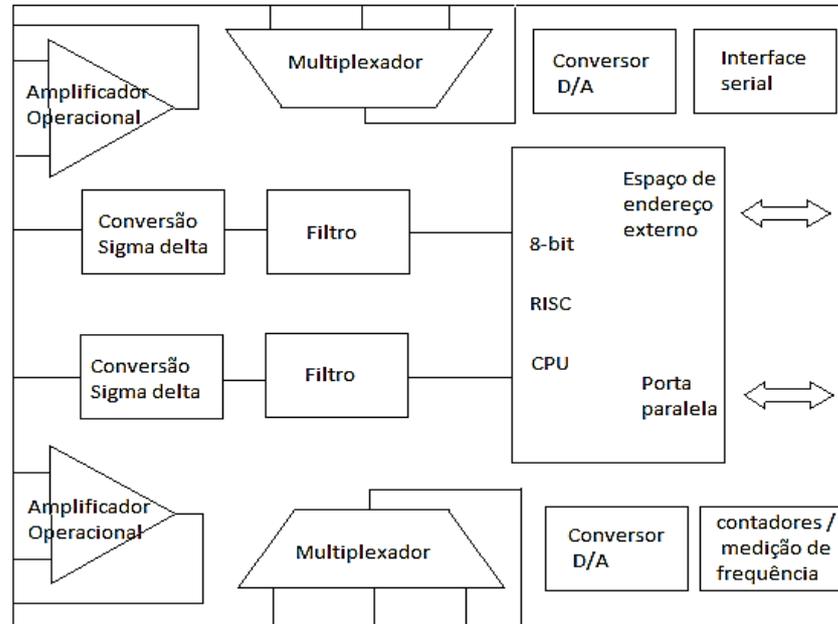
O PC atua como um transmissor de auto validação, executando cálculos de detecção, validação e medição de falhas e incertezas.

Em 1993 os professores Yang e Clarke (1997) desenvolveram sensores autovalidantes de temperatura (YANG e CLARKE, 1997), logo depois, foi desenvolvido por Clarke e Fraher (1996) sensores autovalidantes de oxigênio dissolvido (CLARKE e FRAHER, 1996 apud FENG et al., 2007), que foram aplicados com esta arquitetura baseada nos sensores de comercialização da empresa Foxboro.

A desvantagem dessa arquitetura é possuir um grande volume sem flexibilidade. As vantagens são que a arquitetura é muito simples e há vários recursos de software e hardware disponíveis. Foi a plataforma que foi selecionada pela primeira vez para projetar e desenvolver o sensor SEVA naquela época. Hector et al. (1998) desenvolveram arquitetura de hardware de auto-validação com o sistema de microcomputador Motorola MEK6809D4 / MEK6809KPD, que pode se comunicar com outros dispositivos por meio de sinal de 8 canais A / D com 8 dígitos. Pesquisadores aplicaram essa arquitetura nos dispositivos militares, como o diagnóstico de falhas de sensores em reatores nucleares, aeronaves avançadas e plantas químicas. Por mais que essa arquitetura tenha vantagens de baixo volume e portabilidade, em muitos casos, não podem ser estendidas a outros tipos de sensores devido à sua baixa plasticidade.

Wilson (WILSON e HOPKINS, 1995; WILSON et al., 1996 apud FENG et al., 2007) desenvolveram o circuito de interface de sensor universal (USIC) com interface de comunicação RS-485 e processador RISC para implementar transformada de dois canais de A / D, D / A. A Figura 13 mostra o diagrama de blocos funcional da USIC. Ele tem sido usado

para medição de voltagem para sensor de pressão e medição de capacitância para sensores baseados em capacitância.



**Figura 13- Diagrama de Blocos Funcional da USIC**

**Fonte: WILSON et al., 1995**

A vantagem dessa arquitetura de hardware é a eficiência de custo. A desvantagem é que qualquer mudança na função estendida e modificada deve ser implementada a partir do novo design da arquitetura de hardware.

Para o desenvolvimento da plataforma de hardware de sensores SEVA de uso geral, o departamento de controle de Oxford cooperou com o laboratório de computação para configurar o projeto Valcard (HENRY, 1995a, b, 2001; HENRY et al., 1996; ZHOU et al., 1999 apud FENG et al., 2007) onde visava a arquitetura de hardware do sensor SEVA de uso geral baseada em FPGA. Essa arquitetura possui uma série de unidades de cálculo e unidades de entrada e saída. O primeiro poderia diagnosticar a falha, este último poderia se comunicar com o centro de controle. Todas as funções do hardware podem ser implementadas por software. Assim, os designers poderiam desenvolver as funções de hardware, assim como desenvolvem o software. Isso apresenta a finalidade geral da arquitetura de hardware e a portabilidade e flexibilidade para a modificação.

O sensor SEVA nesta arquitetura de hardware é portátil e de baixo volume, o que satisfaz a necessidade de comercialização. No esquema de validação do coriolis implementado usando a arquitetura Valcard, cada ponto de captação de sinal dentro do transmissor coriolis é

conectado diretamente à placa filha apropriada em um dos módulos FPGA. Os dados passam pelos módulos FPGA para um módulo, que realiza cálculos de medição, detecção de falhas e validação e, em seguida, passa os dados de medição validados para o PC hospedeiro. Com o desenvolvimento do projeto Valcard, algumas arquiteturas de hardware de sensores SEVA baseadas em FPGA foram projetadas. Eles foram usados para projetar os sensores autovalidantes de temperatura, o de oxigênio dissolvido e o de fluxo digital de Coriolis (HENRY, 1999, 1995a, b, 2001a, b; HENRY et al., 2003, 2000 apud FENG et al., 2007).

Os experimentos de teste dos sensores de fluxo de massa digital de auto-validação de coriolis estavam na fábrica de papel no Alabama da América e na fábrica de produtos químicos Terneuzen da Holanda.

A Mahmoud Wagdy implementou o sistema de auto-validação de sensores para fornos de cúpula usando FPGAs (MAHMOUD et al., 2004 apud FENG et al., 2007). Atia et al. (1995) desenvolveu um sensor de temperatura de auto-validação usando FPGA.

O uso de tecnologia digital, particularmente microprocessadores embutidos, pode melhorar o desempenho de um medidor de vazão de várias maneiras. Por exemplo, compensação de temperatura, eliminação de desvio, geração de unidades de engenharia, diagnósticos. Um sensor SEVA usa seu poder de processamento embutido para gerar medidas genéricas de qualidade, com base na incerteza on-line. Esta incerteza inclui todos os fatores que efetuam a medição on-line, incluindo diagnósticos, e também aspectos de fabricação, tais como os componentes utilizados e o procedimento de caracterização.

Henry (2001) desenvolveu um protótipo SEVA medidor de fluxo de massa coriolis construído principalmente a partir de componentes digitais, que fornece compensação para as falhas e limitações de fabricação. O protótipo foi desenvolvido usando uma abordagem de co-design de hardware / software em que virtualmente todos os aspectos do design são descritos em software, mas podem ser implementados de forma flexível em hardware ou software de acordo com requisitos. Essa abordagem oferece aos fabricantes a oportunidade de incorporar rapidamente os componentes mais recentes em seus produtos (HENRY, 2001).

Liu et al. (2014) propôs um *soft sensor* probabilístico de auto-validação com a capacidade de realizar autodiagnóstico, auto-reconstrução e medição de incerteza online para estações de tratamento de águas residuais (ETEs). Nas ETEs os sensores flexíveis são vistos como um simples estimador de sinal para quantidades difíceis de se medir. No entanto, a presença de dados não confiáveis, aliada à crescente demanda por garantia de qualidade de medição, tornou essa visão simplista inadequada. Um pré-tratamento baseado em *Variational*

*Bayesian Principal Component Analysis* (VBPCA) é executado para lidar com valores ausentes e defeituosos antes da modelagem realizada pelo *soft-sensor*. Nesse contexto, a coleta de dados para modelagem de sensores flexíveis (dados fáceis de medir) é validada por um modelo VBPCA antes de executar uma construção de modelo de sensor flexível (LIU et al. 2014).

Chen et al. (2015) propôs uma estratégia baseada no *Grey Bootstrap Method* (GBM) para validação de dados online e estimativa de incerteza dinâmica de sensores multifuncionais de auto-validação. O algoritmo de validação de dados e o princípio de funcionamento baseado no GBM são aplicados para detecção, isolamento e recuperação de falhas múltiplas. O esquema FDIR proposto isola simultaneamente múltiplas falhas de sensores multifuncionais e realiza recuperação de falhas com alta precisão. Além disso, tem um bom desempenho de discriminar entre sinais livres de falhas com mudanças repentinas e falhas indubitáveis. Por causa da distribuição de probabilidade desconhecida e do pequeno tamanho da amostra, a expressão tradicional de incerteza tem limitação nas medidas dinâmicas. Como um método baseado em dados, o GBM pode avaliar a incerteza de medição a partir de informações ruins sem informações prévias sobre a distribuição de probabilidade do mensurando em tempo real. Um índice baseado em um espaço de projeto integral é proposto para o controle de qualidade inferencial (CHEN et al. 2015).

Um protótipo de um sensor de gás de autovalidante foi desenvolvido por Chen et al. (2016) para melhorar a confiabilidade de suas medições. O modelo estatístico multivariado baseado em análise de componente principal executa a detecção de falhas usando a estatística de erro de predição quadrada e pode localizar o sensor defeituoso na matriz do sensor de gás usando um gráfico de contribuição de variáveis.

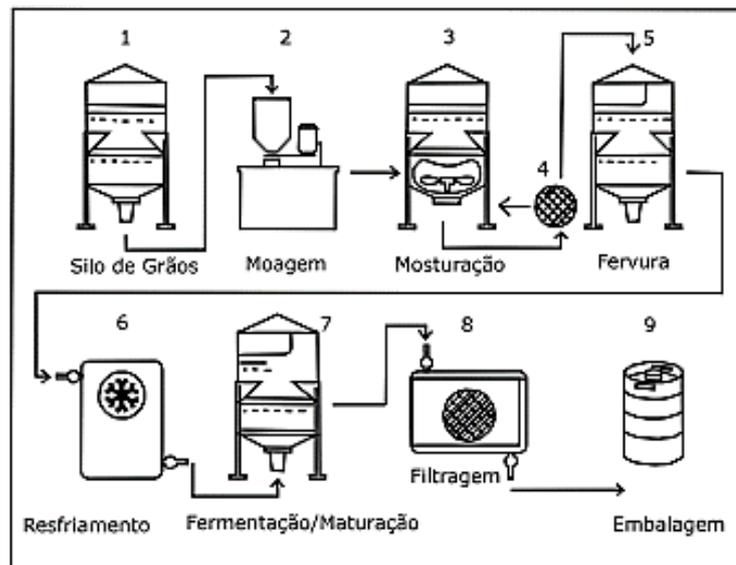
Godoy et al. (2017) apresenta uma técnica integral para projetar um controle de qualidade inferencial aplicável a processos multivariados. A técnica inclui um *soft sensor* autovalidante e um índice de controle de qualidade multivariado que depende das especificações. Com base em uma decomposição de mínimos quadrados parciais (*Partial Least Squares* - PLS) das medições de processo on-line, uma técnica de detecção e diagnóstico de falhas é usada para desenvolver uma estratégia de auto-validação aprimorada que seja capaz de confirmar, corrigir ou rejeitar as previsões do *soft-sensor*. Extrapolações de modelo, distúrbios ou falhas de sensor são detectados pela primeira vez através de uma estatística combinada (que considera a região de calibração); então, um diagnóstico é feito combinando o reconhecimento

de padrões estatísticos, a análise de contribuição e o isolamento de distúrbios com base em padrões históricos de falhas. Um alarme fora das especificações é produzido quando o índice proposto detecta que um ponto de operação está fora do espaço de projeto integral orientado pelas especificações. A eficácia da técnica proposta é avaliada por meio de dois exemplos numéricos (GODOY et al 2017).

## 5. Estudo de Caso:

No Brasil houve um grande aumento na produção das cervejas artesanais e caseiras nos últimos anos. Para a produção da cerveja, uma das tarefas mais importantes é o controle da temperatura durante todo o processo, pois cada etapa exige uma dada temperatura, o que é normalmente trabalhoso e inexato. A temperatura é a segunda grandeza mais medida da natureza, perdendo apenas para o tempo. O controle e a medida dessa variável são muito importantes tanto nos processos industriais quanto no dia-a-dia.

De acordo com Beckhauser<sup>2</sup> (1984 apud FERNANDES; FRANZEN 2011, p. 2), a produção artesanal de cerveja resume-se basicamente em dez passos: elaboração da receita, moagem do grão, mostura, filtração do mosto, fervura, resfriamento, aeração e inoculação do fermento, fermentação, maturação, filtração da cerveja e engarrafamento, como ilustrado na Figura 14.



**Figura 14- Etapas da produção de cerveja Artesanal**

**Fonte: PARIZOTTO, 2017**

Na fabricação caseira de cerveja, geralmente são utilizados: panelas de inox ou alumínio, fogão a gás, termômetros, timer digital, densímetro, refratômetro, entre outros dispositivos para auxiliar o operador. Para controlar a temperatura faz-se o uso de um ajuste manual do registro do gás, controlando assim a intensidade da chama. A temperatura é aferida com o auxílio de um termômetro. O tempo do processo e da adição de lúpulos exige que utilize-se um timer (HUGHES, 2014 apud ).

Nos processos caseiros, normalmente a disponibilidade de recursos tecnológicos de baixo custo que sejam adaptáveis a equipamentos de pequeno porte e que permitam o controle automático da temperatura e tempo do processo nas etapas de mosturação e fervura são menores. Assim, exige-se uma intervenção e monitoramento humano constante durante essas duas etapas.

Supondo o uso de uma panela de fabricação de cerveja onde a temperatura é medida através de um termômetro de resistência (RTD). O funcionamento deste tipo de equipamento consiste na variação da resistência elétrica de um metal, em função da variação da temperatura. A termoresistência de platina, conhecida como PT100, é comumente utilizada e apresenta uma resistência ôhmica de  $100 \Omega$  a  $0^\circ\text{C}$ . Que possui uma faixa de operação que varia de  $-200$  a  $+850^\circ\text{C}$ . Uma maneira de medir a temperatura quando empregado um sensor RTD é a utilização de circuitos em ponte, como a de wheatstone, convertendo a variação da resistência em um sinal elétrico de tensão ou corrente. Após a conversão, cabe adequar o sinal elétrico para níveis aceitáveis, sendo possível, assim, a utilização de dispositivos como microcontroladores ou computadores para a aquisição e processamento desse sinal (BEASLEY; FIGLIOLA, 2007 apud PARIZOTTO, 2017).

Como visto, a temperatura no processo de fabricação da cerveja tem uma importância muito grande. Empregar uma inteligência artificial a esse sistema traria melhorias ao desempenho, maior confiabilidade e robustez do controle, pelo fato de agregar um tipo de conhecimento. O uso das redes neurais, poderia ser empregado para que se pudesse aproveitar a capacidade que essas redes têm de aprendizado e aproximação de funções, de uma forma que elas aprendam essa curva de calibração do sensor PT-100. Através do conhecimento do padrão e variação curva, é possível a correção dos erros causados pela descalibração e mostrar quando o sensor não está calibrado.

Para esse caso apresentado acima, pode-se utilizar uma rede neural Perceptron de Múltiplas Camadas treinada pelo algoritmo Backprogramation, com uma arquitetura de rede 2-3-2-1. Essa arquitetura tem em sua estrutura uma camada com duas entradas, duas camadas escondidas com 3 e 2 neurônios e uma camada com uma saída. As camadas têm a função de ativar a tangente sigmóide, menos a última, que tem função de ativação puramente linear. A partir de três algoritmos é possível realizar a Auto-Correção, a Auto-Verificação e a Auto-Validação.

De acordo com (PEREIRA, 2006) a Auto- Correção ocorre através de um algoritmo e seu objetivo é corrigir o erro provocado pelas alterações na forma da curva de calibração do

sensor. Ela funciona da seguinte forma: um sensor descalibrado em funcionamento, denominado sensor comum, terá suas medidas interceptadas por uma rede neural que tem conhecimento do tempo de funcionamento do sensor. Essa rede deve ser capaz de saber quanto o sensor está descalibrado baseando-se no seu tempo de funcionamento, de forma a corrigir o erro de medição. Para corrigir o erro é necessário que a rede neural passe por uma fase de treinamento, onde um conjunto de dados que contém a medição de um sensor descalibrado para vários valores de entrada e o seu tempo de funcionamento são apresentadas a uma rede Neural *Perceptron* de Múltiplas Camadas. Os dados são então comparados a dados de um sensor calibrado, denominado sensor padrão, fazendo gerar um sinal de erro que o algoritmo da *backprogragation* utilizará para realizar o ajuste dos pesos da rede neural.

A realização de uma Auto-Correção não significa que o sensor não necessitará de uma nova calibração mais para a frente. Vai surgir um momento em que ele deverá ser calibrado novamente, a questão é saber qual o momento ideal para realizar essa calibração. Para isso existe um algoritmo de Auto-Verificação.

Na Auto-Verificação, um sensor descalibrado é associado a uma Rede Neural *Perceptron* de Múltiplas Camadas para que ela possa capturar suas indicações e seu tempo de funcionamento. Baseado nessas informações o erro de medição do sensor é estimado pela rede neural. Na fase de treinamento, a rede neural recebe as informações indicadas pelo sensor descalibrado e o seu tempo de funcionamento. O erro de medição do sensor é comparado com a saída da rede, com base nessa comparação, os pesos da rede devem ser modificados para que ela aprenda como o sinal de erro se comporta com o tempo. Esses algoritmos de Auto-Correção e auto-Verificação fazem com que o sensor se torne inteligente e robusto durante o seu funcionamento em campo. O algoritmo de Auto-Validação serve como complemento do sistema proposto, aumentando a sua confiabilidade.

O algoritmo de Auto-Validação verifica quando o sistema proposto funciona de forma correta. Para isso o sinal gerado pelo algoritmo de Auto-Correção e o sinal gerado pelo algoritmo de Auto-Verificação somado com o sinal do sensor descalibrado devem ser iguais. Quando os sinais são diferentes, o algoritmo dá um aviso de que o sistema não está funcionando bem e pode ser que as Redes Neurais necessitem de novos treinamentos.

Pode-se realizar essa simulação através do Matlab e posteriormente desenvolver um firmware para que possa coletar os dados do PT-100 e realizar essa validação afim de compensar os erros de medição decorrentes da mudança na forma de calibração do sensor.

## **6. CONCLUSÕES E SUGESTÕES PARA TRABALHOS FUTUROS**

### **6.1. Conclusões:**

Nos processos industriais os sensores têm um papel de extrema importância. Mas com o tempo ele vai sofrendo desgastes naturais, fazendo com que sua curva de calibração deforme, o que compromete o seu bom funcionamento, gerando medidas equivocadas. Normalmente a calibração dos sensores é realizada em laboratório, necessitando o interromper o processo para a retirada do sensor.

Na expectativa de aumentar a vida útil do sensor sem a necessidade de retirá-lo da linha de produção para a recalibração, foi desenvolvido o sensor autovalidante. O sensor autovalidante é uma nova geração de sensores, que não apenas produz o valor de medição, mas também estima seu desempenho e estado. O uso do sensor autovalidante em um sistema de medição e monitoramento, traz muitos benefícios. Com seu uso, a confiabilidade do sistema será aumentada, o tempo de máquinas ociosas será reduzido, fazendo com que aumente assim a produção com qualidade e eficiência.

### **6.2. Sugestões Para Trabalhos Futuros:**

Com base no estudo realizado sobre o sensor SEVA, é possível notar a relevância de seu uso e de se explorar mais possibilidades para a realização dessa autovalidação. A pesquisa envolvendo essa nova tecnologia, introduzindo inteligência artificial na instrumentação, mostra que avanços nessa área poderão auxiliar ainda mais os processos industriais e o dia-a-dia, tornando o controle dos instrumentos mais precisos.

Como perspectivas para trabalhos futuros, fica a possibilidade de realizar um sistema autovalidante para o estudo de caso proposto no capítulo 5, baseado em redes Neurais e é importante também realizar investigações de novos métodos de validação e calibração, analisar a possibilidade de extensão de funções dos algoritmos inteligentes para que eles realizem a detecção de falhas nos processos, estudar técnicas de controle avançado com inteligência artificial.

## REFERÊNCIAS

- BARBERREE, D. “*The next generation of thermocouples for the turbine engine industry*”, In: International Instrumentation Symposium, n. 48, pp. 419-29; 2002.
- BHUYAN, M. **Instrumentação Inteligente - Princípios e Aplicações**. 1. ed. Rio de Janeiro: LTC, 2013.
- CHEN, Y., JIANG, S., YANG, J., SONG, K. and WANG, Q., “*Gray bootstrap method for data validation and dynamic uncertainty estimation of self-validating multifunctional sensors*”, Chemometrics and Intelligent Laboratory Systems, Vol. 146, pp. 63-76; 2015
- FENG, Z.; WANG, O.; SHIDA, K. "A review of self- validating sensor technology", **Sensor Review**, v. 27 ,n: 1, pp.48-56. Harbin Institute of Technology, Harbin, China, 2007.
- FRANK, R. “*Understanding smart sensors*”. 2.ed. Boston/ London: Artech house, 2000.
- GODOY, J., MARCHETTI, J.L., VEJA, J.R. “An integral approach to inferential quality control with self-validating soft-sensors”, **Jornal of Process Control**, v.50, pp. 56-65; Argentina: Elsevier, 2017.
- HAYKIN, S. **Redes Neurais- Princípios e aplicações**. Ed.lugar:Bookman, 2001.
- HENRY, M.P. “*Intelligent sensors and the need for new metrics*”, In: IEE Colloquium (Digest), v. 3, pp. 1-3, 1994.
- HENRY, M.P. e CLARKE, D.W. “*The self validating sensor: rationale, definitions and examples*”, **Control Engineering Practice**, v. 1 n. 4, pp. 585-610, 1993.
- HENRY, M.P. “User requirements for measurement validation”, In: IEE Colloquium (Digest), v. 9, pp. 1-7, 1996.
- HENRY, M.P. “On-line compensation in a digital coriolis mass flow meter”, **Flow Measurement and Instrumentation**, Vol. 12 No. 2, pp. 147-61, 2001.
- HINES, J. W., UHRIG, R. E., BLACK, C. e XU, X.” An evaluation of instrument calibration monitoring using artificial neural networks, In: 8th International Conference on Nuclear Engineering”. **Proceedings of ICON 8.**, Baltimore, MD, USA, pp. 1–9, 2000.

- HINES, J. W. e GARVEY, D. “*Process and equipment monitoring methodologies applied to sensor calibration monitoring*”, “*Quality and Reliability Engineering International*” 23(1): 123–135, 2007.
- KRAMER, M. A. “*Nonlinear principal component analysis using autoassociative neural networks*”, **AICHE Journal** v.37, n.2: 233–243, 1991.
- LIU, Y., CHEN, J., SUN, Z., LI, Y.,HWANG, D. “*A probabilistic self-validating soft-sensor with application to wastewater treatment*”. **Computers and Chemical Engineering**, China: Elsevier, pp. 263-280, 2014.
- NAJAFI, M., GULP, C. e LANGARI, R. “*Enhanced autoassociative neural networks for sensor diagnostics (eaann)*”, In: IEEE International Conference on Fuzzy Systems, Proceedings., Vol. 1, pp. 453–456, 2004.
- PEREIRA, D.; BEZERRA, J.; DUARTE NETO, A.; MELO, J. Instrumentação Inteligente aplicada ao Processo de Medição de Vazão e BSW. In: XV Congresso Brasileiro de Automática, Gramado, RS; 2004.
- PEREIRA, D. R, V. Algoritmos Inteligentes para Auto-Correção, Auto- Verificação e Auto-Validação de medidas de sensores. 2006. Dissertação ( Mestrado em Engenharia Elétrica)- UFRN, Natal.
- PIEZOTTO, G. Automação de Equipamentos para Fabricação de Cerveja Artesanal. 2017. Trabalho de Conclusão de Curso (Engenharia Elétrica)- UTFP, Pato Branco.
- SÁNCHEZ, J.E.R.; VELLASCO, M.M.B.R.; TANSCHKEIT,R. Auto-Correção E Validação De Medidas De Sensores Usando Redes Neurais Auto-Associativas. In: X SBAI – Simpósio Brasileiro de Automação Inteligente, 2011, São João del-Rei- MG.
- SÁNCHEZ, J.E.R.; VELLASCO, M.M.B.R.; TANSCHKEIT,R. Sistemas de Inferência Fuzzy para Auto-Compensação e Auto-Validação em Sensores Inteligentes. In: XVIII Congresso Brasileiro de Automática, Bonito-MS, 2010.
- THEILLIOL, D., NOURA, H. e PONSART, J.-C., “*Fault diagnosis and accommodation of a three-tank system based on analytical redundancy*”, *ISA Transactions* v.41, n.3: 365– 382, 2002.

THOMAZINI, D.; ALBUQUERQUE, P. U. B. de. **Sensores Industriais - Fundamentos e Aplicações**. 4. ed. Ceará: Éricar, 2005.

TIAN, G.Y.; ZHAO, Z.X.; BAINES, R.W. (1999). A Fielbus-based Intelligent Sensor. **Mechatronics**, v. 10, pp. 835-849.

WILSON, P.D., SPRAGGS, R.S. e HOPKINS, S.P., “Universal sensor interface chip (USIC): specification and applications outline”, **Sensor Review**, v. 16, n. 1, pp. 18-21, 1996.

WRIGHT, C.” *Information Conversion Separates Noise Levels So You Can Control Them*”, **Personal Engineering & Instrumentation News**, 1993, pp. 63-67.

REYES,J., TANSCHUIT, R., VELLASCO, M., Monitoramento e Diagnóstico de Múltiplos Sensores por Redes Neurais Auto-Associativas. **Revista Controle e Automação**, Vol.23, no.2, Rio de Janeiro, 2012.