

Survey: A utilização de ANFIS voltados para aplicações eHealth

Rodrigo B. Lambrecht¹

¹Mestrado em Engenharia Eletrônica e Computação – Universidade Católica de Pelotas (UCPEL)
– Pelotas – RS – Brazil

Abstract. *The follow-up and monitoring of a patient's vital signs demands a great need to be present in a hospital environment, because of this the use of IOT has been made in order to assist health professionals, bringing practicality through panels and of artificial intelligence, more specifically the use of ANFIS, for prediction of diagnoses. This survey gathers articles related to the theme and a comparison between them.*

Resumo. *O acompanhamento e monitoramento de sinais vitais de um paciente demanda uma grande necessidade de o mesmo se fazer presente junto à um ambiente hospitalar, em função disto tem se feito uso da IOT afim de auxiliar os profissionais da saúde, trazendo praticidade através de dashboards e de inteligência artificial, mais especificamente o uso de ANFIS, para predição de diagnósticos. Este survey reúne artigos relacionados ao tema e uma comparação entre eles.*

1. Introdução

As instituições de saúde podem usar sistemas de apoio à decisão como uma ferramenta para redução de custos. A assistência médica normalmente inclui um grande número de registros de pacientes, múltiplos diagnósticos de doenças e gerenciamento de recursos. Diante deste cenário, o amplo desenvolvimento da Internet das Coisas (IoT) e seu uso em pesquisas médicas melhorou a eficácia dos sistemas de monitoramento remoto de saúde. Inclusive trazendo uma forte crescente do termo IoMT.

Além disso, a utilização de sistemas baseados em inteligência artificial para o apoio no diagnóstico médico têm se mostrado válida e com um grande potencial. Dentre os sistemas de inteligência artificial alguns se destacam, e dentre estes estão os sistemas baseados em lógica fuzzy, redes neurais artificiais (RNA) e sistemas híbridos Neuro-Fuzzy. Sistemas baseados em lógica fuzzy são dotados com a capacidade de trabalhar com imprecisões e incertezas. Com o auxílio das suas regras “SE-ENTÃO”, a lógica fuzzy assemelha-se ao método de decisão humano, onde os resultados e decisões podem apresentar várias possibilidades com diferentes graus de precisão e pertinência.

As redes neurais artificiais são sistemas com capacidade de adaptação e armazenamento de conhecimento. Apresentam a capacidade de aprender a partir de dados, fornecidos na entrada do sistema. Esses dados são processados nas suas camadas, sendo ajustados os seus parâmetros para alcançar resultados cada vez mais fiéis aos padrões inseridos no início do processo de treinamento. Apesar de serem dois tipos de sistemas com grandes êxitos, as redes neurais artificiais e os sistemas de inferência baseados na lógica fuzzy possuem certos pontos negativos quando um alto desempenho é exigido, como por exemplo,

em sistemas com um excessivo número de variáveis de entrada. A dependência de uma grande quantidade de dados para reinamento das redes neurais e um demorado número de regras para os sistemas fuzzy são alguns deles.

O restante do texto está organizado nas seguintes seções. A Seção 2 traz o embasamento teórico de Lógica Fuzzy; a Seção 3 traz o embasamento teórico dos sistemas neuro-fuzzy; a Seção 4 apresenta os trabalhos relacionando; por fim, a Seção 5 conclui o survey.

2. Lógica Fuzzy

Na maior parte dos casos, nossa compreensão da maioria dos processos físicos é baseada na razão e na imprecisão humana. Segundo [Ross 2010], essa imprecisão (quando comparada à precisão requerida pelos computadores) é nada menos que uma forma de informação que pode ser bastante útil aos humanos.

A lógica fuzzy tem a premissa de que todas as coisas são questões de graus e pertinências. Dessa forma, a lógica fuzzy reduz casos como preto-branco e lógicas matemáticas em relações cinzas, por exemplo. Apesar de sistemas baseados na lógica fuzzy terem se mostrado aproximadores universais a funções algébricas, essa não é a principal característica que traga o fuzzy como uma lógica com grande potencial de aplicação. A característica primária oferecida pela lógica fuzzy é a possibilidade de aproximação do comportamento de sistemas onde as relações numéricas ou funções analíticas não se fazem presentes. Sistemas que não apresentam essas características citadas, que nunca foram testados ou que envolvem condições humanas são caracterizados como sistemas complexos, sendo estes, os tipos de sistemas onde a lógica fuzzy possui um alto potencial de resolução. Além de ser aplicável em sistemas complexos, a lógica fuzzy também pode ser aplicada a problemas comuns, de menor complexidade, onde soluções exatas não são necessárias, como por exemplo, quando o problema ou sistema a ser resolvido ou modelado necessita de uma solução aproximada e rápida [Ross 2010].

2.1. Sistema de inferência Fuzzy

Os Sistemas de inferência baseados na lógica fuzzy armazenam regras que são definidas previamente por associações ou senso-comum. Quando uma pergunta é feita ou uma entrada é inserida no sistema de inferência, o sistema fuzzy analisa cada regra armazenada em seu banco em paralelo, mas em graus diferentes, com o intuito de inferir uma saída ou uma conclusão. Este sistema de inferência fuzzy (FIS) consiste basicamente em quatro etapas, sendo elas: a base de regras fuzzy, o sistema de inferência fuzzy e os processos de fuzzificação e defuzzificação [Klir and Yuan 1995]. A ordem desses processos pode ser vista na Figura 1.

2.1.1. Fuzzificação

Após serem inseridas as variáveis de entrada, é realizado o processo de fuzzificação. Esse processo realiza a transformação de uma variável escalar em uma variável linguística, acrescida de um valor de pertinência (entre 0 a 1) a cada conjunto fuzzy presente no sistema. Essa transformação é realizada com o auxílio de funções de associações.

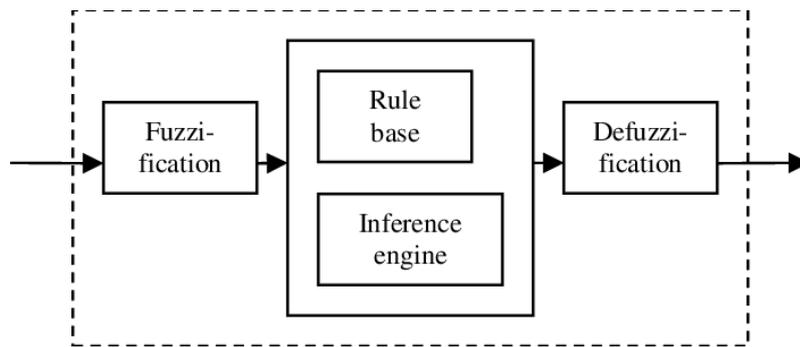


Figure 1. Sistema de Inferência Fuzzy

2.1.2. Sistema de inferência

Após o processo de fuzzificação, os valores obtidos das entradas são aplicados aos antecedentes armazenados na base de regras. Se determinada regra apresenta vários antecedentes, o valor único de saída que representa o resultado da validação anterior é obtido através do operador fuzzy, “E” ou “OU”.

2.1.3. Defuzzificação

O processo de defuzzificação tem como objetivo converter cada uma das decisões tomadas pelo sistema de inferência em um número real e preciso, visto que até então, eram expressas em conjuntos fuzzy.

3. Sistemas Neuro-Fuzzy

De acordo com [Gurney 2004] O cérebro humano é constituído por aproximadamente 100 bilhões de células nervosas ou neurônios, que se comunicam através de sinais elétricos. As ligações entre esses neurônios são realizadas por conexões eletroquímicas, chamadas de sinapses. As sinapses são distribuídas nas extremidades de cada células, denominados dendritos. Em dado momento, um sinal recebido em um neurônio chegará até o corpo da sua célula principal, e posteriormente quando o somatório destes sinais recebidos por esse neurônio atingir um determinado valor, chamado de threshold, ele será ativado e irá emitir um sinal elétrico como resposta a este estímulo. Finalmente esse sinal será transmitido até outros neurônios através dos axônios. Os sinais recebidos pelos neurônios podem produzir um efeito ativador ou inibidor, sendo determinados pelos pesos e sinapses entre os mesmos.

3.1. Redes Neurais Artificiais

As redes neurais artificiais são definidas como sendo um conjunto interconectado de elementos de processamentos simples, unidades ou nós, cuja funcionalidade é baseada no neurônio animal. A habilidade de processamento da rede é armazenada nas conexões interunidades, ou pesos, obtidos por um processo de adaptação, ou aprendizado, oriundo de um conjunto de padrões de treinamento.

3.2. Sistemas Neuro-Fuzzy

O conceito de sistema de inferência neuro-fuzzy adaptativo foi proposto inicialmente por Jang [Jang 1993]. O modelo ANFIS é uma técnica de aprendizado adaptativa que utiliza a lógica fuzzy para transformar entradas de um sistema em valores desejados de saída, combinando os benefícios de aprendizado presentes em sistemas de inferência fuzzy e redes neurais. Por meio do aprendizado supervisionado, o ajuste das funções de associação é feito através do treinamento das redes neurais.

3.2.1. ANFIS

A estrutura do ANFIS é composta por cinco camadas, como mostra. A primeira e a quarta camadas são constituídas por nós adaptativos, enquanto as outras são compostas por nós fixos. As funções de cada uma das camadas são descritas a seguir.

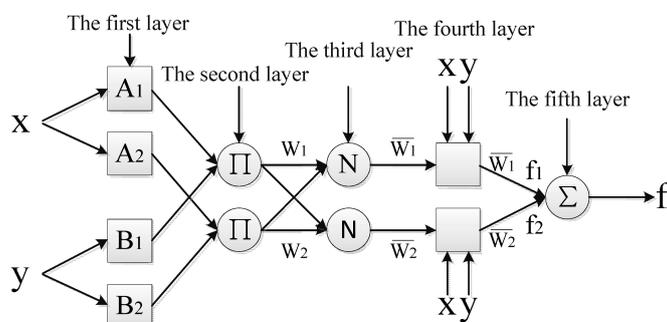


Figure 2. Estrutura ANFIS

- Primeira camada – Cada nó presente nessa camada é adaptativo a um parâmetro de função. A saída dos mesmos é definida por um grau de valor da função de associação. Os parâmetros nessa camada são definidos como parâmetros de premissa;
- Segunda camada – Os nós nessa camada são do tipo fixos, ou não-adaptativos, e são encarregados de multiplicar os sinais recebidos provenientes da primeira camada. Logo após o processo de multiplicação, eles são encarregados de repassar o produto na sua saída até próxima camada. Cada nó presente nessa camada representa o grau de confiança para cada regra;
- Terceira camada – Composta por nós fixos e não-adaptativos, e cada um deles representando a relação entre o n-ésimo grau de confiança das regras e a soma do grau de confiança de todas elas. O sinais de saída dessa camada são definidos como o grau de confiança normalizado;
- Quarta camada – Os nós nessa camada são adaptativos e caracterizados pela seguinte função

$$O^4_i = \bar{w}_i f_i = \bar{w}_i (p_i x + q_i y + r_i) \quad (1)$$

Onde:

$$\bar{w}_i$$

é o grau de confiança normalizado obtido na saída da terceira camada; e

$$(p_i x + q_i y + r_i)$$

são parâmetros presentes no nó. Os parâmetros obtidos nessa camada são definidos como parâmetros de consequência.

- Quinta camada – Constituída por um único nó fixo e não adaptativo, essa camada têm como saída a soma de todos os sinais recebidos por ela.

4. Trabalhos Relacionados

Alguns trabalhos recentes vem utilizando ANFIS voltados para eHealth, seja no auxílio de previsões e diagnósticos, ou para imputar dados faltantes, abaixo seguem os resumos dos principais:

O artigo de [Khan and Algarni 2020] propõe identificar as principais características para a predição de doenças cardíacas por meio de técnicas de aprendizado de máquina. De forma a melhorar a precisão da previsão foi utilizada uma estrutura IoMT com a otimização salp swarm modificada (MSSO) e um sistema de inferência neuro-fuzzy adaptativo (ANFIS), denominado MSSO-ANFIS. O MSSO-ANFIS proposto melhora a capacidade de busca usando o algoritmo de voo de Levy. O processo de aprendizado regular no ANFIS depende do aprendizado baseado em gradientes e tende a ficar preso a mínimos locais. Os parâmetros de aprendizagem são otimizados utilizando MSSO para fornecer melhores resultados para ANFIS. As seguintes informações são retiradas de registros médicos para prever o risco de doença cardíaca: pressão arterial (PA), idade, sexo, dor no peito, colesterol, açúcar no sangue, etc. A condição cardíaca é identificada classificando os dados do sensor recebidos usando MSSO-ANFIS. Uma simulação e análise são realizadas para mostrar que o MSSO-ANFIS funciona bem em relação à previsão de doenças. Os resultados da simulação demonstraram que o modelo de previsão MSSO-ANFIS proposto obtém uma acurácia de 99,45 com uma precisão de 96,54. A proposta pode ser vista na figura 3.

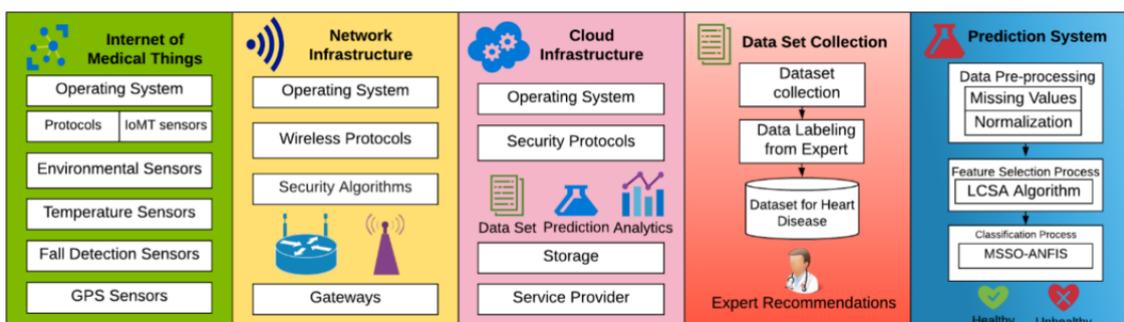


Figure 3. MSSO-ANFIS

O artigo [Hamza Turabieh and Mirjalili 2018] propõe o desenvolvimento de um dispositivo corporal sem fio vestível integrando inteligência neural adaptativa no campo de monitoramento de saúde usando IoT. As unidades sem fio do sensor corporal são capazes de detectar o comportamento dos parâmetros do corpo humano e transmiti-los usando várias análises de dados e técnicas de transmissão. O Sistema de Inferência Neuro-Fuzzy adaptativo (ANFIS) permite ao sistema priorizar os parâmetros fisiológicos coletados dos nós sensores por si só, tornando-o um sistema de monitoramento de saúde inteligente. O modelo proposto foi desenvolvido como um protótipo de um sistema de monitoramento de e-health wearable em tempo real, integrando ANFIS e uma IoT de

código aberto. O modelo consiste em sensores que coletam dados vitais do corpo do paciente e, em seguida, transmite via Wi-Fi à plataforma IoT ThingSpeak. Em um HUB central a lógica fuzzy converte dados brutos em variáveis linguísticas que são treinadas em ANFIS para dar prioridade aos pacientes dependendo do seu estado. Este sistema resulta no fornecimento de dados em tempo real dos pacientes continuamente e transmite os dados priorizados durante a emergência. As figuras 4 e 5 apresentam a arquitetura do sistema e o protótipo.

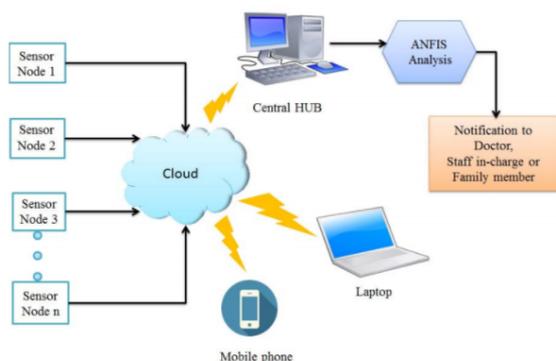


Figure 4. Arquitetura

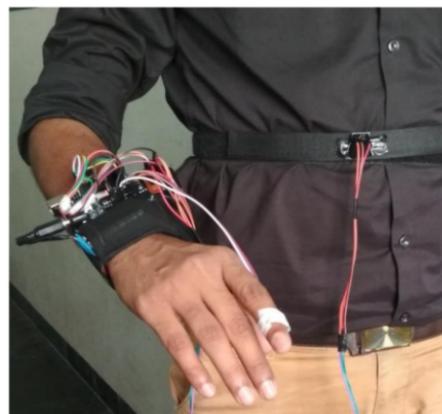


Figure 5. Protótipo

[Khan and Algarni 2019] trouxe uma abordagem de Sistema de Inferência Fuzzy Baseado em Rede Adaptável Dinâmica (D-ANFIS). A proposta visa imputar os valores ausentes de uma maneira simples, mas precisa. A principal contribuição é imputar os valores ausente uma vez recebidos, dividindo os dados coletados em dois grupos: conjunto de dados completo (sem dados ausentes) e conjunto de dados incompletos (com dados ausentes). Um método de validação é usado para treinar o D-ANFIS usando dados completos, enquanto o conjunto de dados incompletos é usado para imputar os valores ausentes. Dois Métodos são usados para avaliar o desempenho final da aplicação IoMT: ANFIS com Algoritmo Genético (ANFIS-GA), e ANFIS com Otimização de Enxame de Partículas (ANFIS-PSO). Os resultados mostram que o desempenho do IoMT é aprimorado em 5% usando ANFIS-GA e em 3% usando ANFIS-PSO. A proposta pode ser vista na figura 6.

No artigo de [Gunasekaran Manogaran and Priyan 2018] á abordada uma aprendizagem de múltiplos Kernel com Sistema de Inferência Neuro-Fuzzy Adaptativo (MKL com ANFIS). O método é proposto para o diagnóstico de doenças cardíacas. o MKL com o método de aprendizado profundo baseado em ANFIS segue uma abordagem dupla. O método MKL é usado para dividir parâmetros entre pacientes com doença cardíaca e indivíduos normais. O resultado obtido com o método MKL é entregue ao classificador ANFIS para classificar as cardiopatias e os pacientes saudáveis. É calculada a Sensibilidade, Especificidade e Erro Quadrado Médio (MSE) para valiar o MKL proposto com o método ANFIS. Também é comparado com outros métodos de aprendizado profundo existentes, como Least Square with Support Vector Machine (LS com SVM), General Discriminant Analysis e Least Square Support Vector Machine (GDA com LS-SVM), Análise de componentes Principais com Sistema de Inferência Neuro-Fuzzy Adaptativo (PCA com ANFIS) e Alocação Latente de Dirichlet com Sistema de Inferência Neuro-Fuzzy Adaptativo

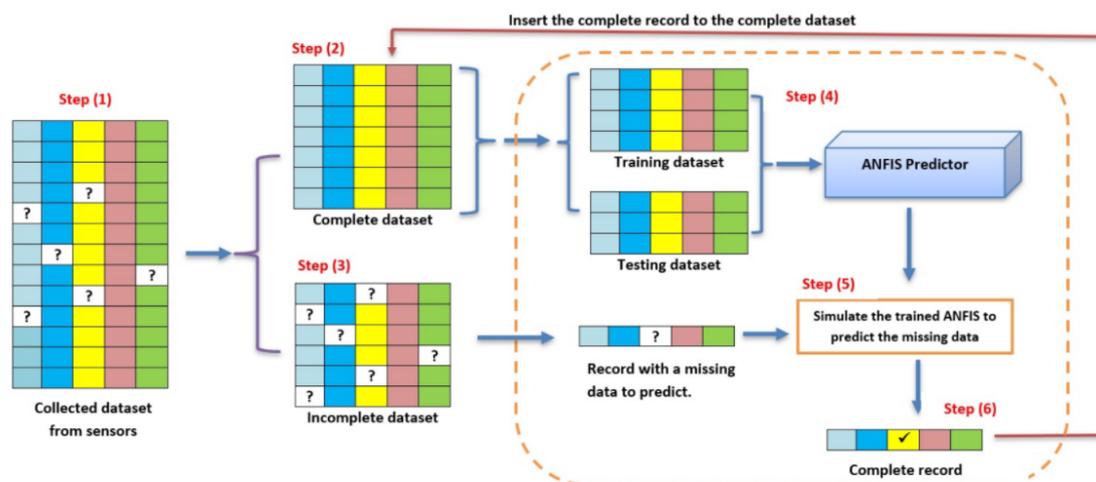


Figure 6. D-ANFIS

(LDA com ANFIS). Os resultados do MKL proposto com o método ANFIS produziram alta sensibilidade (98%), alta especificidade 99%) e menos erro quadrático médio (0,01) para o conjunto de dados KEGG Metabolic Reaction Network.

5. Considerações Finais

É nítida a evolução da IoT na área da saúde, trazendo consigo uma grande área de pesquisa e proporcionando debates ricos em qualidade computacional. Em destaque vemos a lógica fuzzy ganhar cenário juntamente com a utilização de redes neurais, trazendo um sistema híbrido neuro-fuzzy, trazendo situações de incertezas do dia a dia da área de saúde, e transformando-as em informações úteis diante da necessidade de otimização de tempo, seja na triagem ou no acompanhamento de pacientes.

Diante disso abordamos neste survey quatro artigos de relevância para área eHealth com o foco na utilização de Sistemas Neuro-Fuzzy Adaptativo (ANFIS) para auxílio na predição de diagnósticos ou inclusão de dados. Ao analisar os artigos podemos perceber que o foco está na arte por trás da implantação do sistema de inferência ANFIS e também no tratamento de dados antes do treinamento.

Apenas [Hamza Turabieh and Mirjalili 2018] aborda um sistema completo por um todo, desde o sensoriamento à interface final. Também notamos que os resultados apresentados foram satisfatórios, animando a ideia de utilizar os sistemas como apoio de decisão à instituições de saúde.

Concluimos que, como já mencionado durante este Survey, a área de saúde sempre está em constante necessidade de evolução no apoio à diagnósticos e vemos que as situações de predição tem se mostrado promissoras e com um foco recente e com muitos pontos a serem explorados, principalmente relacionando com sistemas embarcados e ANFIS.

References

Gunasekaran Manogaran, R. V. and Priyan, M. K. (2018). Hybrid recommendation system for heart disease diagnosis based on multiple kernel learning with adaptive neuro-

- fuzzy inference system. *Multimed Tools Appl*, 77:4379 – 4399.
- Gurney, K. (2004). *An Introduction to Neural Networks*. Londres e Nova Iorque: UCL Press, 2th edition.
- Hamza Turabieh, M. M. and Mirjalili, S. (2018). A real time healthcare monitoring system based on open source iot and anfis. *International Conference on Intelligent Computing and Control Systems (ICICCS)*, 2.
- Jang, J.-S. R. (1993). Anfis adaptive-network-based fuzzy inference system. *IEEE Transactions on Systems Man and Cybernetics*, 23(3):665–685.
- Khan, M. A. and Algarni, F. (2019). Dynamic adaptive network-based fuzzy inference system (d-anfis) for the imputation of missing data for internet of medical things applications. *IEEE Internet of Things Journal*, 6:9316 – 9325.
- Khan, M. A. and Algarni, F. (2020). A healthcare monitoring system for the diagnosis of heart disease in the iomt cloud environment using mssso-anfis. *IEEE Access*, 8:122259 – 122269.
- Klir, G. J. and Yuan, B. (1995). *Fuzzy Sets and Fuzzy Logic: Theory and Applications*. Upper Saddle River: Prentice-Hall, 1th edition.
- Ross, T. J. (2010). *Fuzzy Logic With Engineering Applications*. John Wiley Sons, 3th edition.