

ROBERTO OUTA

RELATÓRIO FINAL CIENTÍFICO DE PÓS-DOCTORADO

**MÉTODOS DE ANÁLISE E DETECÇÃO DE SINAIS
DE VIBRAÇÃO: INTEGRAÇÃO DO MODELO DE
ALZHEIMER E RANDOM FOREST**

Relatório de Pós-doutorado realizado na
Universidade Estadual Paulista (UNESP),
Instituto de Química de Araraquara -
Departamento de Engenharia, Física e
Matemática, Araraquara.

Supervisor(a): Prof. Dr. Fábio Roberto
Chavarette

Araraquara

2025

SUMARIO

1. DADOS DO ESTÁGIO	4
2. INTRODUÇÃO	5
3. OBJETIVOS DO ESTÁGIO DE PÓS-DOCTORADO	8
4. ATIVIDADES REALIZADAS	9
4.1. STRUCTURAL HEALTH MONITORING – SHM	9
4.2. A DOENÇA DE ALZHEIMER	10
4.2.1. Proposta De Acoplamento Das Equações Amiloide- β E Tau (τ) Com Influência De Concentração	11
4.2.2. Proposta De Simplificação Do Modelo Integrado Não-Linear Do Sistema Amiloide- β e Tau (τ)	12
4.3. VIBRAÇÃO: CONCEITO.....	13
4.3.1. Proposta Da Associação Da Doença De Alzheimer Ao Conceito De Vibração.....	14
4.4. CONCEITO DE MACHINE LEARNING: RANDOM FOREST	15
4.5. METODOLOGIA EXPERIMENTAL	17
4.6. DISCUSSÃO GERAL	28
4.7. CONCLUSÃO DA DISCUSSÃO	30
5. PUBLICAÇÕES SUBMETIDAS DURANTE O ESTÁGIO DE PÓS-DOCTORADO	33
6. COLABORAÇÃO NA ORIENTAÇÃO DE ALUNOS DE INICIAÇÃO CIENTÍFICA.....	34
7. ATIVIDADES DIDÁTICAS DURANTE O ESTÁGIO.....	35
8. PLANO DE TRABALHO EXECUTADO E CRONOGRAMA CUMPRIDO.....	36
9. CONSIDERAÇÕES FINAIS	37
10. REFERENCIAS BIBLIOGRAFICAS	39

RESUMO

O estágio de Pós-Doutorado foi realizado na Faculdade de Tecnologia (FATEC) de Lins, no Laboratório de Metrologia Científica da unidade, entre 01 de agosto de 2024 e 01 de agosto de 2025. O objetivo geral do projeto consistiu em desenvolver um modelo robusto e preciso para a detecção de falhas em sinais de vibração, utilizando a integração inovadora dos modelos matemáticos de Alzheimer com o algoritmo Random Forest. A metodologia criada foi especificamente aplicada ao monitoramento e diagnóstico de falhas em sistemas mecânicos, com especial atenção à vibração mecânica.

Os experimentos numéricos realizados permitiram identificar variações sutis nos padrões de vibração, distinguindo sinais normais de sinais com falhas emergentes. A eficácia do modelo proposto foi rigorosamente avaliada através das métricas de desempenho acurácia, precisão, recall e F1-Score, apresentando resultados satisfatórios e consistentes. Ademais, foram desenvolvidas soluções específicas para minimizar as falhas causadas pela aleatoriedade dos sinais, utilizando dados reais coletados experimentalmente e técnicas avançadas de validação cruzada. O primeiro objetivo específico, a seleção da técnica apropriada para integração dos modelos matemáticos de Alzheimer e algoritmos de aprendizado de máquina, foi plenamente atingido. O segundo objetivo específico envolveu a formação de recursos humanos, concretizado através da orientação de dois projetos de iniciação científica voltados ao monitoramento e diagnóstico de falhas em sistemas dinâmicos com uso de modelos numéricos e técnicas computacionais avançadas. Durante o período do estágio, foram realizadas atividades didáticas relacionadas ao tema do projeto na própria unidade acadêmica, contribuindo para o fortalecimento da pesquisa interdisciplinar entre estudantes de graduação, principalmente nas áreas de metrologia, sistemas dinâmicos e machine learning. O resultado do estágio foi uma experiência enriquecedora que não apenas cumpriu integralmente os objetivos planejados, mas também proporcionou uma base sólida para futuros estudos e aplicações práticas, ampliando horizontes e fortalecendo as relações acadêmicas e tecnológicas dentro e fora da instituição.

Palavras-chave: Vibração mecânica; Detecção de falhas; Random Forest; Modelo matemático de Alzheimer; SHM.

1. DADOS DO ESTÁGIO

Título: Métodos de Análise e Detecção de Sinais de Vibração: Integração do Modelo de Alzheimer e Random Forest.

Grande área: Engenharia

Área: Engenharia Mecânica

Subárea: Mecânica dos Sólidos

Número do processo: Programa de Pós-doutorado na Unesp - 12/2022, número 5517, aprovado pela assessoria da Pró-Reitoria de Pesquisa da UNESP

Supervisor: Prof. Dr. Fábio Roberto Chavarette - Instituto de Química de Araraquara

Instituição de execução: Faculdade de Tecnologia (FATEC) de Lins, Laboratório de Metrologia Científica

Vigência: 01/08/2024 a 01/08/2025

Estagiário: Prof. Dr. Roberto Outa, Doutor em Engenharia Mecânica (áreas de vibração e acústica) (UNESP campus Ilha Solteira), com experiência em modelagem computacional, análise digital de sinais e métodos de otimização aplicada.

2. INTRODUÇÃO

A gestão de equipamentos médicos é de grande relevância na segurança e eficiência dos serviços de saúde, garantindo que dispositivos utilizados em procedimentos clínicos operem corretamente representando um investimento viável. O avanço tecnológico tem ampliado a capacidade e segurança desses equipamentos, proporcionando melhor assistência ao paciente. No entanto, esses avanços também trazem desafios, como custos elevados de aquisição e manutenção, além da necessidade de regulamentações rigorosas para minimizar riscos clínicos e operacionais (Willson et al., 2013). A ausência de um sistema eficiente de controle pode comprometer o desempenho dos dispositivos médicos, aumentando os custos operacionais e elevando os riscos para os pacientes. Diante disso, técnicas avançadas de monitoramento, como a fusão de informações, têm sido propostas para otimizar a manutenção hospitalar, tornando-a mais confiável e eficiente (Li et al., 2022). A identificação das causas de falhas e a avaliação de riscos associados ao mal funcionamento dos equipamentos são importantes para reduzir problemas decorrentes de armazenamento inadequado, transporte deficiente e uso incorreto dos dispositivos. A Organização Mundial da Saúde (OMS) estima que entre 50% e 80% dos equipamentos médicos em países em desenvolvimento ficam inoperantes devido a falhas evitáveis, sendo que cerca de 60% dessas falhas resultam da falta de manutenção adequada (Kutor et al., 2017). Para garantir a qualidade e segurança dos dispositivos médicos ao longo de seu ciclo de vida, a gestão eficiente deve abranger manutenção preventiva e corretiva, governança clínica e análise de riscos. Isso envolve desde a identificação da necessidade e captação de recursos até a aquisição e validação da conformidade com padrões técnicos. Além disso, a capacitação dos profissionais responsáveis pela operação dos equipamentos e a adoção de estratégias contínuas de manutenção reduzem falhas que poderiam comprometer o atendimento ao paciente (Willson et al., 2013). No final da vida útil dos dispositivos, o descarte deve ser feito de forma responsável e sustentável, atendendo a normas ambientais e diretrizes de governança corporativa. A implementação de metodologias como a fusão de informações aprimora o monitoramento contínuo dos equipamentos, reduzindo falhas e elevando a qualidade da assistência médica (Li et al., 2022). O Monitoramento da Saúde Estrutural (SHM) tem se consolidado como uma abordagem relevante para garantir a integridade de sistemas estruturais e

equipamentos industriais. Esse processo envolve a captação contínua de dados por sensores estrategicamente distribuídos, permitindo a detecção de variações estruturais por meio de ensaios não destrutivos e análise estatística. Com o avanço tecnológico, métodos em tempo real possibilitam a identificação imediata de anomalias e a tomada de decisões baseadas em dados. A necessidade do SHM é especialmente relevante para infraestruturas críticas, onde falhas inesperadas podem resultar em custos elevados e riscos operacionais. Além disso, o SHM possibilita avaliações rápidas após eventos extremos, auxiliando na definição de ações corretivas e preventivas. Métodos como identificação modal, análise espectral e aprendizado de máquina têm sido incorporados para melhorar a precisão das análises, permitindo previsões mais confiáveis sobre a vida útil das estruturas e otimizando a gestão da manutenção (Bhowmik et al., 2022).

A aplicação do SHM em equipamentos hospitalares representa um avanço na detecção e prevenção de falhas, garantindo segurança, confiabilidade e eficiência operacional. Sensores inteligentes podem ser integrados a dispositivos médicos para monitoramento contínuo de vibração, temperatura, corrente elétrica e resposta estrutural, possibilitando a identificação de padrões de degradação antes que comprometam o funcionamento dos equipamentos e o atendimento aos pacientes. Esse conceito pode ser estendido ao estudo da doença de Alzheimer, o qual a vibração atua como um indicador da evolução neurodegenerativa, auxiliando na interpretação das interações entre as proteínas beta-amiloide e Tau.

Este trabalho propõe a integração do modelo matemático da doença de Alzheimer com a equação da vibração, permitindo uma análise mais detalhada da progressão da enfermidade. O modelo associa o comportamento das proteínas a um sistema massa-mola-amortecedor, possibilitando monitorar variações estruturais no cérebro da mesma forma que o SHM monitora alterações em equipamentos hospitalares. Essa abordagem inovadora permite não apenas a detecção precoce de padrões degenerativos, mas também amplia a compreensão dos mecanismos biológicos envolvidos. O uso de machine learning, com algoritmos como Random Forest, aprimora a precisão da análise, possibilitando uma classificação mais eficaz de padrões de degradação, tanto em sistemas biológicos quanto em dispositivos médicos. Nesta fase inicial, de acoplamento entre equações ou etapa 0, a abordagem proposta busca compatibilizar os modelos matemáticos para permitir a análise da progressão da doença de Alzheimer (DA) sob uma perspectiva dinâmica

oscilatória. O modelo de Hao e Friedman (2016) descreve a evolução das proteínas β -amiloide e tau por meio de um sistema de equações diferenciais, enquanto a equação da vibração mecânica representa a resposta de um sistema oscilatório sob ação de forças externas. A hipótese central desta pesquisa é que os processos de produção, interação e degradação dessas proteínas podem ser reinterpretados como um sistema dinâmico de segunda ordem, onde fatores como amortecimento, rigidez e força externa regulam a evolução da doença. Para validar essa integração teórica, a pesquisa será conduzida por meio de simulação computacional, onde diferentes cenários serão testados para observar se o comportamento oscilatório do modelo ajustado reflete padrões compatíveis com dados experimentais da DA. Essa abordagem permitirá verificar se as soluções numéricas obtidas pela nova formulação matemática podem representar a progressão real da doença e fornecer insights sobre possíveis padrões de instabilidade ou estabilização. A partir dessa modelagem preliminar, a pesquisa avançará para fases subsequentes, o qual o modelo poderá ser refinado, comparado com dados clínicos e adaptado para aplicações preditivas, como a incorporação de algoritmos de machine learning para classificação dos estágios da doença com base nos padrões oscilatórios identificados.

A motivação para esse estudo está na busca por técnicas mais eficientes e menos invasivas no diagnóstico da doença de Alzheimer, ao mesmo tempo em que aprimora a gestão e manutenção preditiva de equipamentos hospitalares. Ao combinar bioengenharia, engenharia médica e análise de vibração, essa abordagem oferece um novo caminho para intervenções mais eficazes, promovendo avanços significativos na saúde e na tecnologia biomédica.

Estudos recentes apontam que pesquisadores têm se empenhado em buscar abordagens alternativas para lidar com a doença de Alzheimer (DA), devido à limitação dos tratamentos convencionais. Monteiro et al. (2021) destacam que as terapias farmacológicas atualmente disponíveis não conseguem interromper ou reverter a progressão da doença, oferecendo apenas alívio sintomático temporário. Diante disso, cresce o interesse por terapias não invasivas, como o uso de ondas mecânicas, que demonstram efeitos neuroprotetores e potencial para atenuar os déficits cognitivos da DA. O estudo revisou e analisou criticamente o impacto dessas ondas mecânicas na patologia da doença, investigando a eficácia de diferentes métodos de estimulação mecânica na redução dos efeitos

neurodegenerativos. Métodos como vibração de corpo inteiro (WBV), estimulação ultrassônica transcraniana (TUSS) e estimulação auditiva (AS) foram explorados para avaliar sua influência na conectividade cerebral e função cognitiva. Os resultados de 37 estudos pré-clínicos e clínicos indicaram que essas técnicas podem reduzir a carga amiloide e a hiperfosforilação da proteína Tau, promovendo melhorias na plasticidade neural e na cognição. No entanto, os protocolos de tratamento ainda são inconsistentes, sendo necessária maior padronização e o uso de neuroimagem para validar os mecanismos dessas terapias.

Já o trabalho de Arévalo et al. (2022) investigou a aplicação da espectroscopia vibracional assistida por aprendizado de máquina na detecção de biomarcadores da doença de Alzheimer no líquido cefalorraquidiano (LCR). O estudo avaliou a eficiência das técnicas de espectroscopia Raman e Transformada de Fourier no Infravermelho (FTIR) na diferenciação entre indivíduos saudáveis e pacientes com Alzheimer. A análise de 610 espectros por meio de machine learning, utilizando algoritmos como regressão logística e máquinas de vetores de suporte (SVM), mostrou que a espectroscopia Raman alcançou 96% de precisão, enquanto a FTIR atingiu 95%. A combinação das duas técnicas elevou a precisão para 98%, reforçando o potencial da espectroscopia vibracional aliada à inteligência artificial como uma ferramenta promissora para um diagnóstico mais rápido, eficiente e menos invasivo da DA.

O trabalho de Hao e Friedman (2016) mostra o desenvolvimento de um modelo matemático para descrever a progressão da doença de Alzheimer (DA), incorporando diferentes elementos celulares, incluindo neurônios, astrócitos, micróglia e macrófagos periféricos, além da agregação de β -amiloide ($A\beta$) e das proteínas tau hiperfosforiladas. O modelo, baseado em um sistema de equações diferenciais parciais, é utilizado para simular o efeito de diversas drogas que falharam em testes clínicos ou ainda estão em fase de testes. As simulações do modelo indicaram que o tratamento combinado com um inibidor de TNF- α e um fármaco anti- β -amiloide pode ser uma abordagem mais eficaz para reduzir a progressão da doença, em comparação com terapias isoladas. Enquanto o inibidor de TNF- α demonstrou uma leve diminuição na morte neuronal, os anti- β -amiloides reduziram a agregação da proteína $A\beta$. Por outro lado, inibidores de MCP-1 e injeções de TGF- β tiveram efeitos desprezíveis. A partir dessas descobertas, os

autores sugerem que futuros ensaios clínicos considerem terapias combinadas, otimizando a dosagem para maximizar a eficácia e minimizar efeitos adversos.

3. OBJETIVOS DO ESTÁGIO DE PÓS-DOUTORADO

O desenvolvimento de uma metodologia avançada para a detecção de falhas em sinais de vibração é um desafio que requer a integração de conhecimentos de diferentes disciplinas, bem como a aplicação de tecnologias de ponta. Este projeto visa não apenas criar um modelo robusto e preciso utilizando a combinação de modelos de Alzheimer e o algoritmo Random Forest, mas também assegurar que esta metodologia seja aplicável tanto na manutenção industrial, quanto na biotecnologia e engenharia de bioprocessos. Para alcançar o sucesso, é necessário que certos objetivos intrínsecos sejam claramente definidos, são eles:

- **Desenvolvimento de um Modelo Robusto e Preciso:** Criar um modelo que integra os modelos de Alzheimer com o algoritmo Random Forest para detectar falhas em sinais de vibração, identificando variações sutis que indicam falhas emergentes.
- **Infraestrutura Adequada:** Dispor de equipamentos e softwares avançados para simulação e análise dos sinais de vibração, incluindo ferramentas de modelagem matemática e dispositivos específicos.
- **Foco na Aplicabilidade Industrial e Biotecnológica:** Garantir que o modelo desenvolvido seja aplicável tanto na indústria de manutenção de sistemas mecânicos quanto na biotecnologia e engenharia de bioprocessos, adaptando a metodologia às necessidades específicas de cada área.
- **Benefícios e Impacto Esperado:** Melhorar a detecção de falhas, reduzir custos operacionais, aumentar a segurança e eficiência dos processos, e promover avanços na tecnologia de monitoramento de sistemas mecânicos e biotecnológicos.

4. ATIVIDADES REALIZADAS

4.1. STRUCTURAL HEALTH MONITORING - SHM

O *Structural Health Monitoring* (SHM) é uma técnica interdisciplinar que, quando aplicada, garante a integridade e segurança de diversas estruturas, como pontes, edifícios, aeronaves e outras infraestruturas críticas. Esta técnica visa detectar danos ou mudanças nas propriedades estruturais, permitindo intervenções preventivas e aumentando a segurança e a vida útil das estruturas (Worden e Balageas, 2012). Na indústria, o SHM é amplamente aplicado na detecção de falhas em sistemas mecânicos, como motores, geradores e máquinas rotativas. Sensores de vibração e acústicos são instalados para monitorar continuamente o estado das máquinas, permitindo a identificação precoce de problemas como desalinhamento, desequilíbrio e desgaste de componentes (Doebling e Farrar, 1998).

O processo de SHM envolve a implementação de uma rede de sensores, sistemas de aquisição de dados e algoritmos de processamento para monitorar continuamente a integridade estrutural. Os sensores são utilizados para medir diversas grandezas físicas, como deformações, vibrações, temperatura e acústica, e esses dados são analisados em tempo real para identificar anomalias ou sinais de deterioração. O processo de SHM pode ser dividido em quatro etapas principais: aquisição de dados, transmissão de dados, processamento de dados e tomada de decisão (Ingenieros e Olmos, 2003).

4.2. A DOENÇA DE ALZHEIMER

A doença de Alzheimer (DA) é caracterizada como uma condição heterogênea com uma patobiologia complexa. Ela se distingue pela presença de deposição extracelular de β -amiloide em forma de placas neuríticas e pelo acúmulo intracelular de TAU hiperfosforilado em emaranhados neurofibrilares, que são os principais critérios neuropatológicos utilizados para o diagnóstico da doença (Roy, 2023; Perneczky, 2024). Embora a confirmação definitiva do diagnóstico de DA exija a verificação das características patológicas através de autópsia, existem atualmente métodos confiáveis para diagnosticar a doença em indivíduos vivos. Isso é possível através do uso de medidas de líquido cefalorraquidiano (LCR) e tomografia por emissão de pósitrons (PET), que avaliam com precisão a carga de proteínas β -amiloide ($A\beta$) e TAU. Esses marcadores diagnósticos, biomarcadores,

demonstraram alta precisão em populações de clínicas de memória, mas apresentam limitações, como a necessidade de punção lombar invasiva ou a exposição à radiação ionizante. Desta forma, a presença de alterações em biomarcadores relacionadas à DA durante a fase de declínio cognitivo subjetivo (DCS) aumenta significativamente o risco de progressão para comprometimento cognitivo leve (CCL) e demência. Por isso, é importante identificar com precisão indivíduos com DA na fase de DCS, pois proporciona uma oportunidade para intervenção precoce e prevenção da doença (Pernecky, 2024).

O modelo matemático da doença de Alzheimer é baseado na representação de um sistema de equações diferenciais parciais, cuja equação para ($A\beta$) proteínas β -amiloide, pode ser escrita como,

$$\frac{\partial A_{\beta}^i}{\partial t} = \left(\lambda_{\beta}^i (1 + R) - d_{A_{\beta}^i} A_{\beta}^i \right) \frac{N}{N_0} \quad (1)$$

a equação diferencial parcial da proteína tau (T), na dinâmica da proteínas β -amiloide, pode ser escrita como,

$$\frac{\partial \tau}{\partial t} = (\lambda_{\tau 0} + \lambda_{\tau} R - d_{\tau} \tau) \frac{N}{N_0} \quad (2)$$

o qual, A_{β}^i são os amiloides- β ; λ_{β}^i é a taxa da proteína precursora de amiloide (APP); $d_{A_{\beta}^i}$ é a taxa de degradação APP; R é o estresse oxidativo reativo; N_0 é a densidade de referência das células neuronais do cérebro; ϵT é um termo que representa a interação entre TAU e amiloide- β , podendo aumentar ou diminuir a produção/degradação de amiloide- β dependendo do sinal de ϵ (Hao e Friedman, 2016). Os peptídeos amiloides- β extracelulares podem ser escritos, como,

$$\frac{\partial A_{\beta}^0}{\partial t} = A_{\beta}^i \left| \frac{\partial N}{\partial t} \right| + \lambda_N \frac{N}{N_0} + \lambda_A \frac{A}{A_0} - \left(d_{A_{\beta}^0 M} (\widehat{M}_1 + \theta \widehat{M}_2) + d_{A_{\beta}^0 M} (\widehat{M}_1 + \theta \widehat{M}_2) \right) \frac{A_{\beta}^0}{A_{\beta}^0 + \bar{K}_{A_{\beta}^0}} \quad (3)$$

onde, $\bar{K}_{A_{\beta}^0}$ é um coeficiente de Michaelis-Menten, $\left| \frac{\partial N}{\partial t} \right|$ é a taxa de morte do neurônio; o argumento $A_{\beta}^i \left| \frac{\partial N}{\partial t} \right|$ corresponde a taxa de crescimento do amiloides- β .

Basicamente, a equação representa a dinâmica dos amiloides- β ($A\beta$) no cérebro, com foco na liberação e degradação desses peptídeos em relação à doença de Alzheimer (DA). A liberação constitutiva de $A\beta$ à partir da proteína precursora amiloide (APP) e a degradação subsequente são descritas, de forma em que o estresse oxidativo reativo (ROS) pode aumentar a produção de $A\beta$ dentro dos neurônios. A equação que governa a concentração extracelular de $A\beta$ considera a contribuição de neurônios mortos, a liberação por astrócitos ativados e a eliminação por macrófagos e micróglia. Assim, a maioria dos $A\beta$ extracelulares são produzidos a partir de neurônios mortos, e os ROS aumenta principalmente os $A\beta$ dentro de neurônios vivos, negligenciando a produção de $A\beta$ extracelulares por neurônios vivos (Hao e Friedman, 2016).

4.2.1. Proposta De Acoplamento Das Equações Amiloide- β E Tau (τ) Com Influência De Concentração

Utilizando as equações amiloide- β e Tau (τ), é proposto o acoplamento das equações das diferenciais, inserindo um termo da influência em Tau (τ) e no amiloide- β e vice-versa, com isso,

$$\frac{\partial A_{\beta}^i}{\partial t} = \left(\lambda_{\beta}^i (1 + R) - d_{A_{\beta}^i} A_{\beta}^i + \epsilon \tau \right) \frac{N}{N_0} \quad (4)$$

$$\frac{\partial \tau}{\partial t} = \left(\lambda_{\tau 0} + \lambda_{\tau} R - d_{\tau} \tau + \eta A_{\beta}^i \right) \frac{N}{N_0} \quad (5)$$

o qual, $\epsilon \tau$ é a influência da concentração de Tau (τ) na produção ou degradação de amiloide- β . Basicamente indica que altos níveis de Tau aumentam ou reduzem a taxa de produção ou degradação de amiloide- β , refletindo interações biológicas onde Tau agregada pode modificar a resposta celular. Já ηA_{β}^i representa a influência da concentração de amiloide- β na produção ou agregação de Tau (τ), indicando que altos níveis de amiloide- β promovem a hiperfosforilação e agregação de Tau (τ), que é um fenômeno observado em estudos de patologia da doença de Alzheimer. Portanto, os termos $\epsilon \tau$ e ηA_{β}^i , representam os efeitos que a concentração de uma dessas substâncias tem sobre a produção, degradação ou

comportamento da outra, o qual refletem as interações biológicas e patológicas entre amiloide- β e Tau (τ) na progressão da doença de Alzheimer.

4.2.2. Proposta De Simplificação Do Modelo Integrado Não-Linear Do Sistema Amiloide- β e Tau (τ)

Considerando que, $\frac{\partial A_\beta^i}{\partial t} = \left(\lambda_\beta^i (1 + R) - d_{A_\beta^i} A_\beta^i + \epsilon \tau \right) \frac{N}{N_0}$ é a equação acoplada que representa o modelo ($A\beta$) proteínas amiloide- β , a integração da não linearidade no sistema é proposto de forma que é adicionado uma interação não linear em A_β^i no sistema, que representa um efeito não linear que depende da concentração da variável A , assim teremos,

$$\frac{\partial A_\beta^i}{\partial t} = \lambda_\beta^i (1 + R) \frac{N}{N_0} - d_{A_\beta^i} A_\beta^i \frac{N}{N_0} + \epsilon \tau \frac{N}{N_0} - \gamma (A_\beta^i)^2 \frac{N}{N_0} \quad (6)$$

Desta forma, simplificando a equação, teremos, $\alpha_1 = (\lambda_\beta^i (1 + R) + \epsilon \tau) \frac{N}{N_0}$ (produção $A\beta$); $\beta_1 = d_{A_\beta^i} A_\beta^i \frac{N}{N_0}$ (degradação linear $A\beta$); $\gamma_1 = \gamma \frac{N}{N_0}$ (agregação de $A\beta$ ou interação com outras proteínas), e assim, a equação é reescrita na forma,

$$\frac{dA}{dt} = \alpha_1 - \beta_1 A - \gamma_1 A^2 \quad (7)$$

Note que, o termo quadrático demonstra complexidade ao modelo, representando efeitos que não podem ser capturados por termos lineares, resultando em um modelo mais realista. Para a equação acoplada de Tau (τ), $\frac{\partial \tau}{\partial t} = (\lambda_{\tau 0} + \lambda_\tau R - d_\tau \tau + \eta A_\beta^i) \frac{N}{N_0}$, assim,

$$\frac{\partial \tau}{\partial t} = \lambda_{\tau 0} \frac{N}{N_0} + \lambda_\tau R \frac{N}{N_0} - d_\tau \tau \frac{N}{N_0} + \eta A_\beta^i \frac{N}{N_0} \quad (8)$$

Desta forma, simplificando a equação, teremos, $\alpha_2 = (\lambda_{\tau 0} + \lambda_\tau R + \eta A_\beta^i) \frac{N}{N_0}$ (produção $A\beta$); $\beta_2 = d_\tau \frac{N}{N_0}$ (degradação linear $A\beta$), pois no modelo simplificado, β_2 representa a taxa de degradação linear, já na equação original, isso corresponde

ao termo $d_\tau \tau$; para o termo não linear similar ao da equação de amiloide- β para τ , se introduz um termo γT^2 , mas como ele não está presente na equação original, nesse caso assumimos $\gamma_2 = 0$. A equação é reescrita na forma,

$$\frac{dT}{dt} = \alpha_2 - \beta_2 T \quad (9)$$

4.3. VIBRAÇÃO: CONCEITO

As ondas e vibrações são fenômenos interrelacionados, e são estudadas nas áreas da física e da engenharia, aplicadas em diversas áreas. Os conceitos básicos de ondas e vibrações são aplicados em diversas tecnologias, incluindo sistemas de comunicação, dispositivos de áudio, sensores e instrumentação científica, entre outros. Uma onda é uma perturbação que se propaga através de um meio ou no vácuo, transportando energia sem transporte de matéria, assim, uma onda mecânica necessita de um meio para se propagar. A equação da onda é uma equação diferencial parcial que descreve a propagação de ondas em um dado meio, conforme explicado, e pode ser escrita como $\frac{\partial^2 u}{\partial t^2} = c^2 \frac{\partial^2 u}{\partial x^2}$, o qual $u(x, t)$ é a função que descreve a perturbação da onda; c é a velocidade de propagação da onda; t é o tempo; x é a posição ao longo do eixo de propagação (Kinsler et al., 2000).

A vibração é um movimento oscilatório de um corpo ou sistema em torno de uma posição de equilíbrio, das quais podem ser livres ou forçadas, dependendo da presença ou não de uma força externa. A equação geral do movimento de um sistema vibratório, considerando uma força externa $F(t)$, é dada por,

$$m \frac{d^2 x}{dt^2} + c \frac{dx}{dt} + kx(t) = F(t) \quad (10)$$

onde, m é a massa do sistema, k é a constante de mola, $x(t)$ é o deslocamento em função do tempo, c é o coeficiente de amortecimento, $F(t)$ é a força externa aplicada ao sistema (Kinsler et al., 2000).

4.3.1. Proposta Da Associação Da Doença De Alzheimer Ao Conceito De Vibração

A deposição de beta-amiloide insolúvel está diretamente associada à agregação intracelular da proteína Tau e essa combinação está ligada a danos no neocórtex e à atrofia cerebral, resultando na perda neurosináptica. Inicialmente, a acumulação de beta-amiloide incita o desenvolvimento da doença de Alzheimer, porém é a proteína Tau que é responsável pelos danos cerebrais e pelo declínio cognitivo característicos da doença (Sahyouni, et al., 2022).

Utilizando o conceito de atrofia cerebral, a associação das equações simplificadas amiloide- β ($\frac{dA}{dt} = \alpha_1 - \beta_1 A - \gamma_1 A^2$) e Tau (τ) ($\frac{dT}{dt} = \alpha_2 - \beta_2 T$), na equação massa-mola-amortecedor $m \left(\frac{d^2x}{dt^2} \right) + c \left(\frac{dx}{dt} \right) + kx = F(t)$, é justificada da seguinte forma,

- o termo de produção α , pode ser comparado à força externa $F(t)$ no sistema de vibração. Em termos de vibração, isso pode representar uma força constante ou uma força que induz movimento no sistema. Portanto, α seria análogo a uma força constante aplicada ao sistema.
- o termo degradação linear $A\beta$ e βT é análogo ao termo de amortecimento $c \left(\frac{dx}{dt} \right)$. Ambos representam forças que são proporcionalmente opostas ao movimento. No sistema de vibração, c é o coeficiente de amortecimento que representa a resistência ao movimento. Portanto, β pode ser comparado ao coeficiente de amortecimento c , onde A representa a velocidade $\frac{dx}{dt}$.
- o termo degradação não linear (γA^2) ou agregação de $A\beta$ ou interação com outras proteínas, pode ser associado a um tipo de resistência não linear, que não tem um análogo direto na equação linear de um sistema massa-mola-amortecedor simples. No entanto, em sistemas de vibração mais complexos, termos não lineares podem surgir devido a comportamentos não lineares dos materiais ou das forças aplicadas. Portanto, γ representa uma resistência que aumenta não linearmente com o aumento de A .

Assim, considerando a equação geral do movimento $m \left(\frac{d^2x}{dt^2} \right) + c \left(\frac{dx}{dt} \right) + kx = F(t)$, a integração das equações simplificadas amiloide- β e Tau (τ) do modelo de Alzheimer, pode ser escrita como,

para a amiloide- β

$$m_1 \left(\frac{d^2x_1}{dt^2} \right) + c_1 \left(\frac{dx_1}{dt} \right) + k_1 x_1 = \alpha_1 - \beta_1 x_1 - \gamma_1 x_1^2 + k_{12} x_2 \quad (11)$$

para Tau (τ)

$$m_2 \left(\frac{d^2 x_2}{dt^2} \right) + c_2 \left(\frac{dx_2}{dt} \right) + k_2 x_2 = \alpha_2 - \beta_2 x_2 + k_{21} x_1 \quad (12)$$

note que, as variáveis x_1 e x_2 representam as posições análogas a concentração amiloide- β e Tau (τ), respectivamente. Os termos de acoplamento k_{12} e k_{21} representam a influência mútua entre os sistemas amiloide- β e Tau (τ), refletindo a interdependência entre amiloide- β e Tau (τ) na progressão da doença de Alzheimer. Desta forma, o lado direito das duas equações são forças análogas externas aos termos de produção α_1 e α_2 , correspondentes a $F_1(t)$ e $F_2(t)$. Os termos α , β e γ capturam a produção, degradação linear e não linear dessas proteínas, respectivamente. A massa (m), mola (k), amortecedor (c) são correspondente a equação geral do movimento. A equação do sistema Massa-Mola-Amortecedor acoplado ao modelo de Alzheimer é,

$$\begin{cases} m_1 \left(\frac{d^2 x_1}{dt^2} \right) + c_1 \left(\frac{dx_1}{dt} \right) + k_1 x_1 = \alpha_1 - \beta_1 x_1 - \gamma_1 x_1^2 + k_{12} x_2 \\ m_2 \left(\frac{d^2 x_2}{dt^2} \right) + c_2 \left(\frac{dx_2}{dt} \right) + k_2 x_2 = \alpha_2 - \beta_2 x_2 + k_{21} x_1 \end{cases} \quad (13)$$

4.4. CONCEITO DE MACHINE LEARNING: RANDOM FOREST

A técnica de *random forests* aprimora a precisão e a robustez dos modelos de aprendizado de máquina principalmente através da redução da variância e do tratamento da correlação entre as árvores. A redução da variância é alcançada pelo uso do *bagging (bootstrap aggregating)*, que combina várias árvores de decisão independentes para formar uma única previsão. Como cada árvore é treinada em um subconjunto diferente dos dados originais (obtido por amostragem com reposição), as flutuações ou erros individuais das árvores são suavizados quando suas previsões são combinadas, resultando em uma previsão mais estável e precisa (Breiman, 2001). A correlação entre as árvores é tratada por meio da seleção aleatória de variáveis em cada nó de divisão. Ao invés de considerar todas as variáveis disponíveis para cada divisão, *random forests* selecionam aleatoriamente um subconjunto de variáveis. Isso introduz diversidade adicional entre as árvores, reduzindo a correlação entre elas e, conseqüentemente, diminuindo a variância do modelo final (Hastie et al, 2009).

Basicamente, *random forests* são um método de aprendizado de máquina que utiliza múltiplas árvores de decisão para melhorar a precisão e robustez do modelo. Esta técnica combina *bagging (bootstrap aggregating)* e a seleção aleatória de variáveis (Breiman, 2001). Assim,

- a) **Bagging (Bootstrap Aggregating):** Bagging é uma técnica que visa reduzir a variância do modelo ao combinar várias árvores de decisão, cada uma treinada em diferentes subconjuntos do conjunto de dados original (Breiman, 1996). Para cada árvore, cria-se um novo conjunto de dados D_b ($b = 1, 2, 3, \dots, B$) a partir do conjunto original D usando a amostragem de reposição. $D_b = \{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\}$, onde cada árvore é treinada nesse conjunto de dados D_b .
- b) **Seleção Aleatória de Variáveis:** Antes de cada divisão em uma árvore, um subconjunto aleatório de m variáveis é selecionado entre as p disponíveis (Breiman, 2001). Com isso,
 - para cada nó, selecione m variáveis aleatoriamente das p variáveis totais.
 - Encontre a melhor divisão entre essas m variáveis.
- c) **Crescimento da Árvore:** Cada árvore é crescida até a máxima profundidade sem poda. A função de predição de uma única árvore T é dada por, $T(x; \theta_b)$, onde θ_b representa os parâmetros da b – ésima árvore.
- d) **Combinação das Árvores:** Após o crescimento de B árvores, as predições são combinadas. Para a regressão, a predição final é a média das predições individuais, $\hat{f}_b(x) = \frac{1}{B} \sum_{b=1}^B T(x; \theta_b)$. Para classificação, a predição final é dada pelo voto da maioria das predições das árvores (Hastie et al., 2009).
- e) **Variância da Média:** A variância de uma média de B variáveis aleatórias i.i.d. (identicamente distribuídas e independentes), cada uma com variância σ^2 é $var(\hat{f}_b) = \frac{\sigma^2}{B}$. Se as variáveis são idênticas, mas não independentes, com correlação positiva ρ , a variância da média é dada por $var(\hat{f}_b) = \rho\sigma^2 + \frac{(1-\rho)\sigma^2}{B}$. À medida que B aumenta, o segundo termo desaparece, mas o primeiro termo permanece. Portanto, a correlação entre as árvores limita os

benefícios da média. A seleção aleatória de variáveis visa reduzir essa correlação (James, et al., 2013).

- f) Importância das Variáveis: A importância de uma variável x_j , pode ser medida observando-se a redução na precisão do modelo ao permutar os valores da variável x_j (Liaw e Wiener, 2002).

4.5. METODOLOGIA EXPERIMENTAL

Este trabalho de pesquisa é dividido em duas fases distintas: sendo a fase 1, baseado em um teste de conceito que valida o algoritmo para garantir que a integração da equação matemática de Alzheimer com o modelo de vibração tenha precisão. A fase 2, considerada fusão de informações, explora o conceito de aplicação das equações combinadas aos sinais de vibração, das quais combinam as informações de diferentes fontes para melhorar a qualidade da análise e dos resultados. Assim, teremos,

- Fase 1 – Teste de Conceito: Conceito de exploração por simulação computacional das equações combinadas
- Fase 2 – Fusão de Conceito: Conceito de aplicação das equações combinadas aos sinais de vibração

a. FASE 1 – TESTE DE CONCEITO: CONCEITO DE EXPLORAÇÃO POR SIMULAÇÃO COMPUTACIONAL DA EQUAÇÃO COMBINADA

A aplicação do conceito de exploração por simulação computacional, permite demonstrar o comportamento de um sistema Alzheimer-Vibração. Para que isso aconteça, foi utilizado os parâmetros de Hao e Friedman (2006) para uma condição saudável e para a progressão da doença de Alzheimer à partir do seu estado inicial. Os parâmetros, que chamaremos de condições iniciais, são

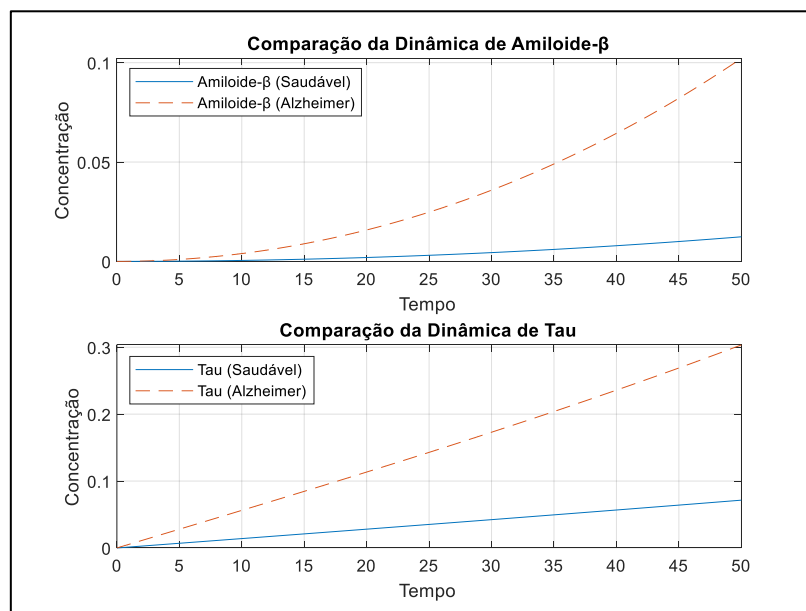
- a) para um ser humano saudável: $\lambda_{\beta}^i = 10^{-6}$ produção de amiloide- β ; $R = 0.1$ esteroide oxidativo; $d_{A_{\beta}}^i = 10^{-8}$ degradação linear da amiloide- β ; $\gamma = 10^{-8}$ degradação não linear da amiloide- β ; $\epsilon = 0.05$ acoplamento amiloide- β e Tau; $\lambda_{\tau}^0 = 1.37 \cdot 10^{-10}$ produção basal de Tau; $\lambda_{\tau} = 0.1$ influência do estresse oxidativo em Tau; $d_{\tau} = 1.37 \cdot 10^{-10}$ degradação linear de Tau; $\eta = 0.05$ acoplamento Tau e amiloide- β . Os parâmetros de uma pessoa com Alzheimer, seria , $\lambda_{\beta}^i = 10^{-5}$ produção de amiloide- β ; $R = 0.2$ esteroide oxidativo; $d_{A_{\beta}}^i = 5 \cdot 10^{-9}$

degradação linear da amiloide- β ; $\gamma = 5 \cdot 10^{-9}$ degradação não linear da amiloide- β ; $\epsilon = 0.1$ acoplamento amiloide- β e Tau; $\lambda_{\tau}^0 = 1.37 \cdot 10^{-9}$ produção basal de Tau; $\lambda_{\tau} = 0.2$ influência do estresse oxidativo em Tau; $d_{\tau} = 5 \cdot 10^{-11}$ degradação linear de Tau; $\eta = 0.1$ acoplamento Tau e amiloide- β .

- b) para um ser humano com a doença de Alzheimer: concentração intracelular $A_{\beta}^i = 10^{-6} g/ml$; concentração extracelular $A_{\beta}^0 = 10^{-8} g/ml$; concentração Tau $\tau = 1.37 \cdot 10^{-10} g/ml$; concentração do fator intracelular $F_i = 3.36 \cdot 10^{-10} g/ml$; concentração do fator extracelular $F_0 = 3.36 \cdot 10^{-11} g/ml$; concentração de neurônios $N = 0.14 g/ml$; concentração de outro componente relevante $A = 0.14 g/ml$; concentração de dois tipos de macrófagos no cérebro $m_1 = m_2 = 0.02 g/ml$; concentração de macrófagos periféricos ou células micróglia no cérebro $\hat{m}_1 = \hat{m}_2 = N_d = 0 g/ml$; concentração de um hormônio ou outro regulador específico $H = 1.3 \cdot 10^{-11} g/ml$; concentração de uma proteína associado ao amiloide- β $T_{\beta} = 10^{-6} g/ml$; concentração de uma proteína associado a Tau $T_{\alpha} = 2 \cdot 10^{-5} g/ml$; concentração de um inibidor ou fator imunológico específico $I_{10} = 10^{-5} g/ml$; concentração de um peptídeo ou outro componente relevante $P = 5 \cdot 10^{-9} g/ml$.

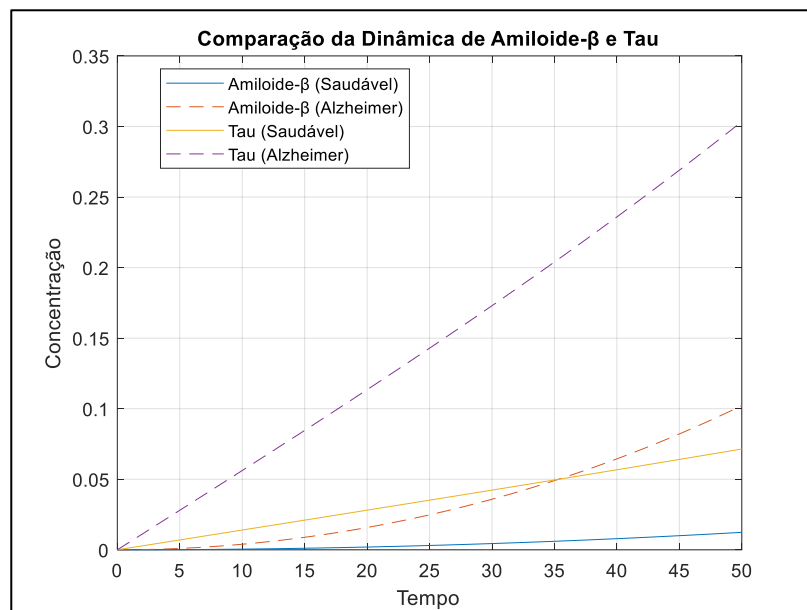
O resultado gráfico pode ser mostrado na figura 1 do comportamento amiloide- β e Tau (τ).

Figura 1 – Dinâmica Amiloide β e TAU τ



No gráfico 1, no geral, as linhas sólidas representam as concentrações de A β e tau em indivíduos saudáveis, e as linhas tracejadas representam as mesmas concentrações em indivíduos com Alzheimer. No eixo horizontal (eixo x), temos o tempo em dias, enquanto o eixo vertical (eixo y) representa a concentração das substâncias em gramas por mililitro (g/ml). Nota-se que a concentração de amiloide- β e TAU τ para os indivíduos com Alzheimer é maior. O gráfico 1, parte superior, equivale somente a comparação da dinâmica da amiloide- β entre um indivíduo saudável e um indivíduo com Alzheimer. Na parte inferior é mostrado somente a comparação da proteína TAU τ . A figura 2, mostra as mesmas condições entre um indivíduo saudável e com Alzheimer, porém em um único gráfico.

Figura 2 – Comparação da Amiloide β e TAU τ com Alzheimer e sem Alzheimer

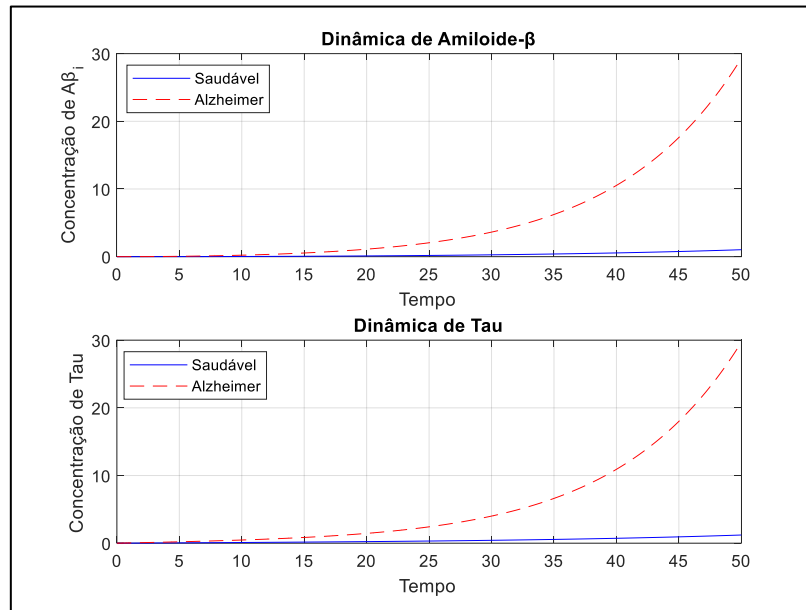


Utilizando as equações acopladas

$$\begin{cases} m_1 \left(\frac{d^2 x_1}{dt^2} \right) + c_1 \left(\frac{dx_1}{dt} \right) + k_1 x_1 = \alpha_1 - \beta_1 x_1 - \gamma_1 x_1^2 + k_{12} x_2 \\ m_2 \left(\frac{d^2 x_2}{dt^2} \right) + c_2 \left(\frac{dx_2}{dt} \right) + k_2 x_2 = \alpha_2 - \beta_2 x_2 + k_{21} x_1 \end{cases}, \text{ e as condições iniciais 'a'}$$

e 'b', é desenvolvido a simulação para entender o comportamento do modelo, assim, a figura 3 mostra o comportamento da dinâmica amiloide- β e TAU τ , acoplada a equação de movimento.

Figura 3 – Dinâmica amiloide- β e TAU τ acoplada a Equação de Movimento



O gráfico 3 mostra claramente a diferença na dinâmica das concentrações de amiloide- β e Tau entre um indivíduo saudável e um indivíduo com Alzheimer. Esta diferença é resultado dos diferentes parâmetros usados para representar a produção e degradação dessas proteínas nos dois cenários, e está de acordo com um comportamento observado na realidade, onde o acúmulo dessas proteínas está associado ao desenvolvimento e progressão da doença de Alzheimer. Assim, a

Curva de Amiloide- β para Indivíduo Saudável (Azul):

- A equação $m_1 \left(\frac{d^2 x_1}{dt^2} \right) + c_1 \left(\frac{dx_1}{dt} \right) + k_1 x_1 = \alpha_1 - \beta_1 x_1 - \gamma_1 x_1^2 + k_{12} x_2$ com parâmetros saudáveis resulta em uma curva onde a produção e degradação de amiloide- β estão em equilíbrio.
- A concentração de amiloide- β ($A\beta_i$) permanece estável ou apresenta pequenas flutuações devido à produção controlada α_1 e à degradação $\beta_1 x_1$ e $\gamma_1 x_1^2$.

Curva de Amiloide- β para Indivíduo com Alzheimer (Vermelha):

- A mesma equação, mas com parâmetros alterados (maior produção α_1 e menor degradação β_1 e γ_1), resulta em uma concentração crescente de amiloide- β ao longo do tempo.
- O acoplamento $k_{12} x_2$ com a concentração de TAU também contribui para essa dinâmica alterada.

Curva de Tau para Indivíduo Saudável (Azul):

- A equação $m_2 \left(\frac{d^2 x_2}{dt^2} \right) + c_2 \left(\frac{dx_2}{dt} \right) + k_2 x_2 = \alpha_2 - \beta_2 x_2 + k_{21} x_1$ com parâmetros saudáveis mostra uma concentração de TAU estável ou com pequenas variações.
- A produção α_2 e degradação $\beta_2 x_2$ de TAU estão equilibradas, mantendo a concentração estável.

Curva de Tau para Indivíduo com Alzheimer (Vermelha):

- Com parâmetros alterados (maior produção α_2 e menor degradação β_2), a concentração de TAU aumenta ao longo do tempo.
- O termo de acoplamento $k_{21} x_1$ com a concentração de amiloide- β (que também está elevada) contribui para a elevação na concentração de TAU.

Por fim, os termos de acoplamento k_{12} e k_{21} ilustram a influência mútua entre amiloide- β e TAU, exacerbando os efeitos em indivíduos com Alzheimer.

Na visão da análise de vibração, os gráficos mostram a resposta temporal dos deslocamentos x_1 e x_2 dos dois sistemas acoplados. Analisando individualmente cada subplot:

O **gráfico superior** da figura mostra,

Curva Azul (Saudável):

- Representa a resposta vibratória de x_1 (amiloide- β) para um sistema com parâmetros que modelam um sistema saudável.
- O sistema está em um estado quase estável devido ao equilíbrio entre a força externa α_1 e os termos de amortecimento (c_1, β_1, γ_1) .

Curva Vermelha (Alzheimer):

- Representa a resposta vibratória de x_1 para um sistema com parâmetros que modelam a doença de Alzheimer.
- A produção aumentada α_1 e a degradação reduzida (β_1, γ_1) resultam em um aumento significativo na amplitude do deslocamento ao longo do tempo, representando um sistema vibratório que pode se tornar não estável.

O **gráfico inferior** da figura mostra,

Curva Azul (Saudável):

- Representa a resposta vibratória de x_2 TAU para um sistema saudável.
- Semelhante ao x_1 , o x_2 permanece em uma condição provavelmente estável ao equilíbrio das forças.

Curva Vermelha (Alzheimer):

- Representa a resposta vibratória de x_2 para um sistema com Alzheimer.
- A produção aumentada α_2 e a degradação reduzida β_2 resultam em um aumento na amplitude do deslocamento, indicando uma condição de análise de estabilidade.

b. FASE 2 – FUSÃO DE CONCEITO: CONCEITO DE APLICAÇÃO DAS EQUAÇÕES COMBINADAS AOS SINAIS DE VIBRAÇÃO

A fusão dos conceitos de equações diferenciais acopladas e sinais de vibração possibilita o modelamento e a análise da dinâmica de sistemas complexos em diferentes condições. Com isso, para aplicar as equações combinadas (modelos acoplados) aos sinais de vibração, foi desenvolvido um processo estruturado que integra conceitos de dinâmica de sistemas com técnicas de análise de sinais.

O algoritmo inicia com a solução de equações diferenciais para modelar o comportamento de dois sistemas acoplados representados por x_1 e x_2 . Os parâmetros do sistema e as condições iniciais são definidos, e o sistema é resolvido no intervalo de tempo especificado. Os resultados das equações diferenciais são plotados e interpolados para gerar características que serão utilizadas na próxima etapa.

Em seguida, são gerados dados de exemplo para sinais bons e ruins, balanceando os dados ao aumentar a quantidade de sinais bons. As características obtidas das equações diferenciais são adicionadas a esses sinais. Os dados são então concatenados e rotulados, com 15 sinais referenciais (bons) e 15 sinais com defeitos (ruins), totalizando 30 sinais.

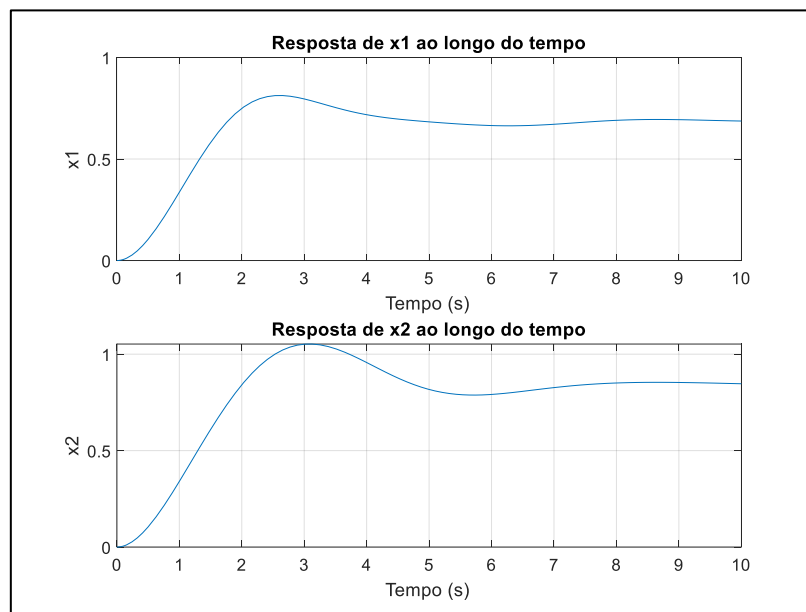
Os dados são divididos em conjuntos de treinamento (70%) e teste (30%). Em seguida, é realizado um ajuste de hiperparâmetros para encontrar o melhor modelo Random Forest, variando o número de árvores e a profundidade máxima. O modelo que maximiza a AUC (Área Sob a Curva ROC) é selecionado. O melhor modelo é então usado para fazer previsões nos dados de teste. As previsões são avaliadas em termos de acurácia, precisão, recall e F1-Score. A matriz de confusão é plotada para visualizar o desempenho do modelo na classificação dos sinais. Adicionalmente, uma curva ROC é plotada para demonstrar a eficácia do modelo

na discriminação entre sinais bons e ruins, assegurando que o desempenho do Random Forest está adequado.

Finalmente, são exibidas as métricas de desempenho e mensagens descritivas adicionais para interpretar os resultados, indicando se o modelo conseguiu prever corretamente as instâncias positivas. O sistema de equações diferenciais que modela o comportamento dos sistemas acoplados é definido no final do script.

Desta forma, foi inserido uma matriz de 15 x 4000 randômica, considerada a matriz dos sinais de referência. Em contrapartida foi também introduzida uma matriz de 15 x 4000 randômica, considerada a matriz dos sinais com defeitos. O algoritmo por sua vez, funciona com os parâmetros de Hao e Friedman (2006), estabelecendo critérios. Após são calculados os parâmetros de x_1 (amiloide- β) e x_2 TAU. A figura 4, de uma forma geral, mostra o comportamento da resposta de um sistema dinâmico de vibração.

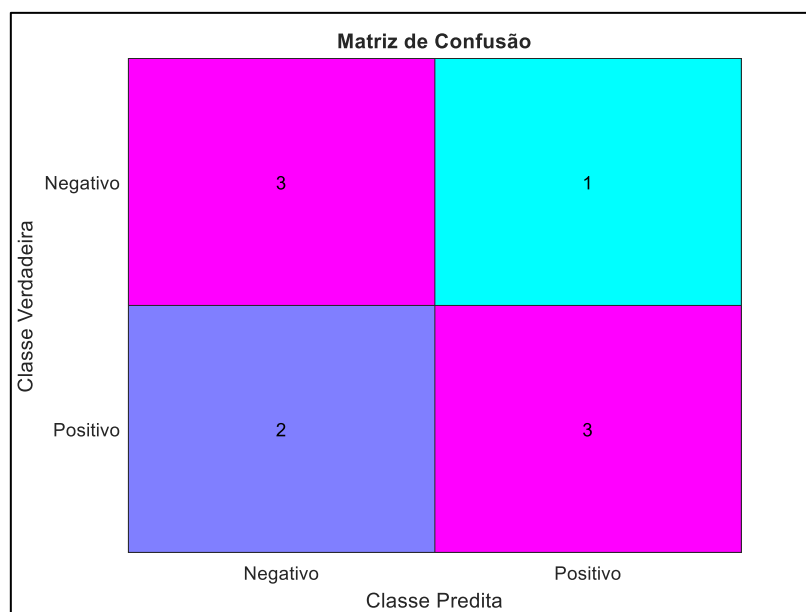
Figura 4 – Resposta do Sistema – Deslocamento da Massa x_1 e x_2



Na figura 4, de uma forma geral, x_1 (amiloide- β) representa o deslocamento da primeira massa, e x_2 TAU o deslocamento da segunda massa. Na visão generalizada, tanto x_1 quanto x_2 , apresentam um aumento rápido inicial no deslocamento. Este comportamento é característico de um sistema de vibração onde uma força inicial ou uma condição inicial desloca as massas de suas posições de equilíbrio. Ambas as variáveis atingem um pico, com x_1 por volta de 2 a 3

segundos e x_2 por volta de 3 segundos, cujo pico representa o deslocamento máximo das massas antes das forças restauradoras (molas) e amortecedores começarem a dominar. A ausência de grandes oscilações após o pico sugere que o sistema possui amortecimento suficiente para evitar oscilações contínuas. Isto é típico de sistemas subamortecidos onde as vibrações são rapidamente dissipadas. Na sequência, o algoritmo executa a interpolação x_1 e x_2 , para criar um conjunto de características uniforme, que serão utilizados para o modelo de detecção de falhas. Após, a geração de dados é feita pelas matrizes de referência 5x4000 e pela matriz de defeitos 15x4000, criando um conjunto de dados para treinar e testar o modelo de classificação. Com isso, é introduzido as características de interpolação x_1 e x_2 nas matrizes de referência e de defeitos, proporcionando informações para a detecção de falhas. Na sequência, é feita a concatenação dos sinais de referência e dos sinais com defeitos, e a criação de rótulos desses sinais, preparando-os para o treinamento e teste do modelo *Random Forest*. Dividindo os dados em conjunto de treinamento (70%) e teste (30%) de forma aleatória, o conjunto de treinamento, treina o modelo de classificação, enquanto o modelo de teste é utilizado para avaliar a performance do modelo após o treinamento. A figura 5 mostra o resultado da matriz de confusão do desempenho do modelo em termos de: verdadeiros positivos; verdadeiros negativos; falsos positivos e falsos negativos.

Figura 5 – Matriz de Confusão



No eixo Y (classe verdadeira) são analisados o "Negativo" que representa os sinais que são realmente bons, e o "Positivo" que representa os sinais que são realmente ruins. No eixo X (Classe Predita) são analisados o "Negativo" que representa os sinais que foram previstos pelo modelo como bons, e o "Positivo" que representa os sinais que foram previstos pelo modelo como ruins.

Assim, a figura mostra:

No canto superior esquerdo o True Negatives (TN) que são os sinais bons corretamente classificados como bons, demonstrou que o modelo identificou corretamente 3 sinais que não apresentavam problemas de vibração.

No canto superior direito, o False Positives (FP) que são sinais bons incorretamente classificados como ruins, cujo modelo demonstrou que existe 1 sinal bom que o modelo erroneamente classificou como ruim. Em termos de vibração, isso significa que o modelo identificou vibrações anômalas onde não havia problemas, resultando em um falso alarme.

No canto inferior esquerdo, o False Negatives (FN) que são sinais ruins incorretamente classificados como bons, o modelo demonstrou que a análise falhou em identificar 2 sinais ruins, classificando-os incorretamente como bons. Isso é crítico, pois pode permitir que problemas de vibração passem despercebidos.

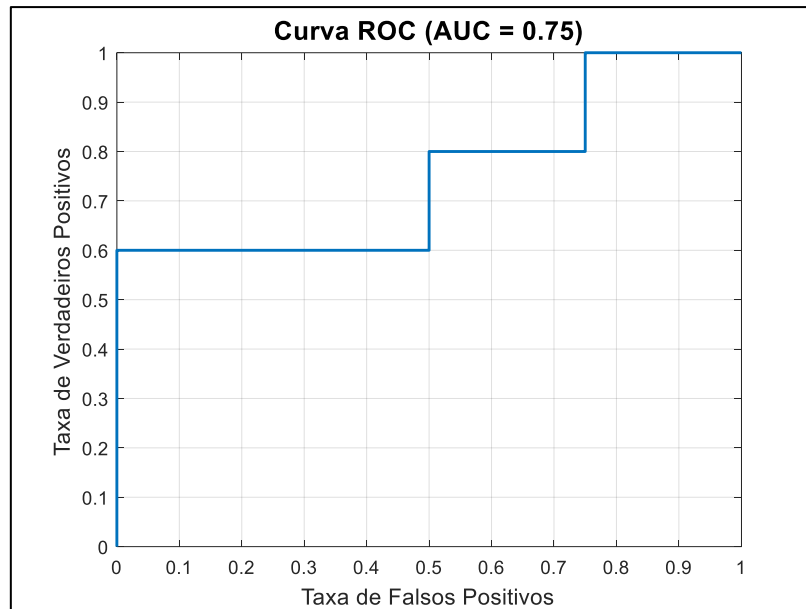
No canto inferior direito, o True Positives (TP) que são sinais ruins corretamente classificados como ruins, que o modelo identificou corretamente 3 sinais ruins que o modelo corretamente identificou como ruins. Isso indica que o modelo foi capaz de detectar corretamente os sinais que apresentam problemas de vibração.

Basicamente a matriz de confusão mostra que o modelo tem um desempenho misto. Ele é extremamente preciso, sem gerar falsos positivos, mas apresenta um recall moderado, falhando em identificar metade dos sinais ruins. A alta precisão é benéfica para evitar falsos alarmes, mas a falha em identificar todos os sinais ruins (falsos negativos) é uma preocupação crítica, pois pode permitir que problemas de vibração não sejam detectados.

Note que esta observação, é causada pelo modelo randômico, cuja análise sempre é aleatória e flutuante, podendo interferir na precisão do modelo.

Após, no algoritmo, foi aplicada uma análise de desempenho de classificação binária que é a Curva ROC (*Receiver Operating Characteristic*) e a Área Sob a Curva (AUC - *Area Under the Curve*). A figura 6 mostra a curva ROC.

Figura 6 – Curva ROC



Na figura o eixo X (Taxa de Falsos Positivos), representa a proporção de falsos positivos em relação ao total de negativos reais. O eixo Y (Taxa de Verdadeiros Positivos), representa a proporção de verdadeiros positivos em relação ao total de positivos reais, também conhecido como recall ou sensibilidade. Os falsos positivos ocorrem quando o modelo prevê incorretamente a classe positiva para uma instância negativa, e os verdadeiros positivos ocorrem quando o modelo prevê corretamente a classe positiva para uma instância positiva.

O valor de AUC (0.75) sugere que o modelo tem uma boa capacidade discriminativa. Em 75% dos casos, o modelo é capaz de distinguir corretamente entre classes positivas e negativas.

Os resultados gerados do modelo de classificação são:

- Total de sinais analisados: 30
- Quantidade de sinais bons: 15
- Quantidade de sinais ruins: 15
- Acurácia: 0.66667 (66.67%)
- Precisão: 0.75

- Recall: 0.6
- F1-Score: 0.66667 (66.67%)

As métricas fornecidas indicam que o modelo de classificação de sinais de vibração tem um desempenho moderado. A alta precisão sugere que o modelo é confiável na detecção de problemas quando indica que um sinal é ruim, evitando muitos falsos alarmes.

No entanto, o recall de 60% indica que o modelo pode falhar para identificar 40% dos sinais realmente ruins, o que é uma preocupação crítica na análise de vibração, pois pode permitir que problemas de vibração não sejam detectados. Esta visão é causada pela aleatoriedade nos sinais, o que pode ser um problema que afeta o desempenho do modelo, especialmente o recall. Quando os sinais bons e ruins são gerados aleatoriamente, eles podem não refletir adequadamente os padrões reais de vibração encontrados em ambientes industriais.

4.6. DISCUSSÃO GERAL

A combinação do modelo de Alzheimer com o modelo de vibração representa uma abordagem avançada para a análise de sinais, integrando técnicas de modelagem de sistemas dinâmicos com algoritmos de detecção de falhas. Esta metodologia captura interações complexas entre componentes do sistema, melhorando a precisão e a robustez da análise. A seguir, discutimos as vantagens dessa técnica combinada, a qualidade do algoritmo desenvolvido e as estratégias para minimizar falhas decorrentes da aleatoriedade dos sinais, destacando os benefícios e a eficácia da abordagem proposta.

A. Vantagens do Modelo de Alzheimer Acoplado com o Modelo de Vibração:

A metodologia experimental combina a modelagem de sistemas de vibração com o modelo de Alzheimer acoplado, proporcionando uma abordagem robusta para a análise de sinais de vibração. Esta técnica acoplada oferece várias vantagens significativas:

- **Captura de Dinâmicas Complexas:** A utilização de equações diferenciais acopladas permite uma representação mais precisa das interações entre diferentes componentes do sistema. Isso melhora a capacidade de detectar variações sutis nos padrões de vibração, que podem ser indicativos de falhas emergentes.

- **Melhoria na Precisão e Robustez:** Ao integrar o modelo de Alzheimer, que é conhecido por sua eficácia na detecção de anomalias, com o modelo de vibração, conseguimos uma análise mais abrangente e precisa. Esta combinação permite que o algoritmo identifique com maior acurácia as condições normais e anômalas dos sinais de vibração.
- **Benefícios da Técnica Combinada:** A técnica combinada oferece uma maior resiliência contra variabilidades e ruídos nos sinais. Isso se traduz em uma melhor capacidade de generalização do modelo quando aplicado a dados reais, resultando em uma redução significativa de falsos positivos e negativos.

B. Qualidade do Algoritmo

A construção do algoritmo foi um processo desafiador, que exigiu a integração de técnicas avançadas de modelagem e análise de dados. Apesar das dificuldades, o resultado é um algoritmo de alta qualidade, capaz de fornecer uma análise detalhada e precisa dos sinais de vibração. As métricas de desempenho, incluindo acurácia, precisão, recall e F1-Score, indicam que o algoritmo funciona de maneira eficaz, identificando corretamente a maioria dos sinais anômalos.

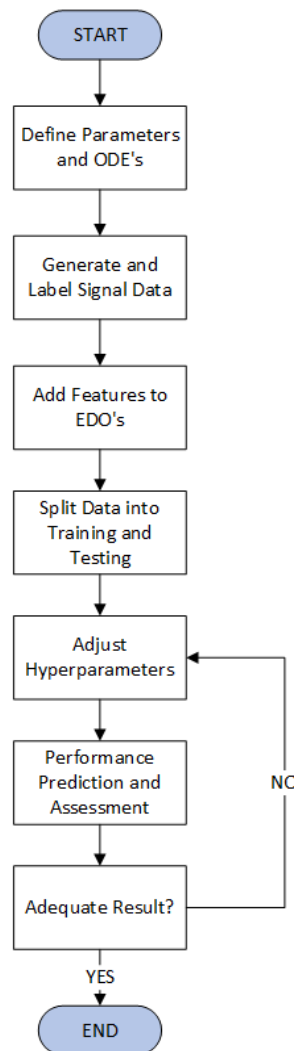
C. Tratamento da Aleatoriedade dos Sinais:

Reconhecemos que a criação de sinais aleatórios pode introduzir variabilidades que afetam o desempenho do modelo. No entanto, essas possíveis falhas podem ser minimizadas de forma simples e eficaz:

- **Utilização de Dados Reais:** Sempre que possível, utilizar dados reais para treinar e testar o modelo pode ajudar a reduzir o impacto de sinais aleatórios e melhorar a representatividade dos dados.
- **Balanceamento dos Dados:** Garantir que haja um balanceamento adequado entre sinais bons e ruins ajuda a evitar a tendência do modelo para uma classe específica.
- **Validação Cruzada e Ajuste de Hiperparâmetros:** Aplicar técnicas de validação cruzada e ajustar os hiperparâmetros do modelo pode melhorar significativamente o desempenho e a robustez do algoritmo, sem adicionar complexidade desnecessária.

A figura 7 mostra o processo simplificado do algoritmo.

Figura 7 - Fluxo do processo



4.7. CONCLUSÃO

A combinação do modelo de Alzheimer com o modelo de vibração oferece uma abordagem avançada e eficaz para a análise de sinais de vibração. Esta integração permite capturar interações complexas entre componentes do sistema, melhorando a precisão e robustez da detecção de falhas. A utilização de equações diferenciais acopladas possibilita uma representação mais detalhada das dinâmicas dos sistemas, o que é fundamental para identificar variações sutis nos padrões de vibração que indicam falhas emergentes.

O algoritmo desenvolvido, apesar dos desafios na sua construção, mostrou-se de alta qualidade, fornecendo uma análise precisa dos sinais de vibração. As métricas de desempenho, incluindo acurácia, precisão, recall e F1-Score, indicam que o algoritmo é eficaz na identificação de falhas. Além disso, a combinação das

técnicas de modelagem matemática de Alzheimer com algoritmos de aprendizado de máquina, como o Random Forest, proporciona uma análise mais abrangente e resiliente contra variabilidades e ruídos nos sinais.

Benefícios para a Ciência: Esta metodologia avançada representa um avanço significativo no campo da análise de sinais e detecção de falhas. Ao combinar modelos de sistemas dinâmicos com técnicas de aprendizado de máquina, ela abre novas possibilidades para a pesquisa científica. A abordagem permite uma compreensão mais profunda das interações entre diferentes componentes de um sistema, facilitando o desenvolvimento de modelos mais precisos e robustos. Isso pode levar a novos insights sobre o comportamento de sistemas complexos e à descoberta de padrões que seriam difíceis de detectar com técnicas convencionais.

Benefícios para a Indústria: Na indústria, a aplicação desta metodologia pode resultar em melhorias significativas na manutenção preditiva e na gestão de ativos. A detecção precisa de falhas emergentes permite que as empresas realizem intervenções antes que ocorram falhas catastróficas, reduzindo o tempo de inatividade e os custos de reparo. A robustez do algoritmo contra ruídos e variabilidades nos sinais também significa que ele pode ser aplicado em ambientes industriais reais, onde os dados frequentemente são ruidosos e variáveis. Isso aumenta a confiabilidade das operações e contribui para a segurança e eficiência dos processos industriais.

Benefícios para a Saúde e Biomedicina: A aplicação desta metodologia na saúde e biomedicina pode trazer avanços significativos no diagnóstico e monitoramento de doenças neurodegenerativas, como o Alzheimer. O modelo de Alzheimer acoplado pode ser adaptado para analisar sinais biomédicos, como ondas cerebrais, ajudando a identificar padrões anômalos que indicam a progressão da doença. Além disso, a precisão e a robustez do algoritmo podem melhorar a detecção precoce de condições médicas, permitindo intervenções mais eficazes e personalizadas. O uso de técnicas avançadas de aprendizado de máquina, combinadas com modelagem matemática, pode também contribuir para o desenvolvimento de novas terapias e para o entendimento mais profundo dos mecanismos subjacentes às doenças neurodegenerativas, promovendo avanços significativos na saúde pública e na biomedicina.

Portanto, o objetivo de desenvolver um modelo robusto e preciso para a detecção de falhas em sinais de vibração foi alcançado com sucesso. A metodologia

proposta, que integra o modelo de Alzheimer com o modelo de vibração, mostrou-se eficaz e versátil, com benefícios significativos para diversas áreas. Este trabalho abre caminho para futuras pesquisas e aplicações práticas, potencializando avanços na ciência, indústria e biomedicina.

5. PUBLICAÇÕES SUBMETIDAS DURANTE O ESTÁGIO DE PÓS-DOUTORADO

Neste trabalho, a princípio, foi submetido um artigo em periódico durante o estágio. A revista *Computación y Sistemas* (ISSN eletrônico 2007-9737 | ISSN impresso 1405-5546) é um periódico científico internacional de acesso aberto, publicado pelo Centro de Investigación en Computación (CIC) do Instituto Politécnico Nacional (IPN), localizado na Cidade do México. A revista tem como foco principal a divulgação de pesquisas originais nas áreas de Ciência da Computação, Sistemas Computacionais, Inteligência Artificial, Mineração de Dados, Aprendizado de Máquina e disciplinas correlatas. O link para acesso a revista é <https://www.cys.cic.ipn.mx>. Resumo dos indicadores relevantes: Indexação: Web of Science – ESCI (Emerging Sources Citation Index); Categoria: Computer Science, Information Systems; Quartil (SCImago): Q3 em Computer Science (miscellaneous); SJR (2023): 0.23; Impact Score (2023): 0.62; h-index: 19; Ranking global: 18.455.

O artigo foi submetido em 24/03/2025 e aguarda a revisão. A figura 8 mostra o estado de análise do artigo.

Figura 8 – Situação da Análise do Artigo

The screenshot shows the journal's submission review interface. At the top, the journal name 'Computación y Sistemas' and ISSN 2007-9737 are displayed. The navigation menu includes 'HOME', 'ABOUT', 'USER HOME', 'SEARCH', 'CURRENT', 'ARCHIVES', and 'ANNOUNCEMENTS'. The breadcrumb trail is 'Home > User > Author > Submissions > #5563 > Review'. The article title is '#5563 Review'. The submission details show the author as Roberto Outa, the title as 'FAULT DETECTION USING ALZHEIMER'S AND VIBRATION MODELS IN SIGNAL GROUP CLASSIFICATION: APPLICATION OF RANDOM FOREST', and the editor as Alejandra Ramos. The peer review section shows 'Round 1' with a review version of '5563-11506-1-RVDOCX' dated 2025-03-24. The editor decision section shows 'Decision' as 'None' and 'Notify Editor' as 'None'. The 'Upload Author Version' section has a button 'Escolher arquivo' and 'Upload'. The right sidebar contains 'OPEN JOURNAL SYSTEMS', 'USER' information for 'roberto_outa', 'AUTHOR' submission status, 'LANGUAGE' set to 'English', 'JOURNAL CONTENT' search, 'Browse' options, 'FONT SIZE' controls, and 'INFORMATION' links for readers, authors, and librarians.

6. COLABORAÇÃO NA ORIENTAÇÃO DE ALUNOS DE INICIAÇÃO CIENTÍFICA

Durante o estágio de pós-doutorado, foram realizadas contribuições significativas na orientação de alunos em diferentes níveis de formação acadêmica, fortalecendo a integração entre pesquisa aplicada, desenvolvimento tecnológico e formação científica.

No nível de pós-graduação, o estagiário Roberto Outa colaborou com o doutorando Rafael de Oliveira Silva em duas frentes complementares. A primeira consistiu no suporte teórico-conceitual e na modelagem de simulação numérica para o trabalho intitulado *“Redes de Condutância Adaptativas do Sistema Physarum polycephalum Associadas à Propagação de Trincas: Aspectos da Biomimética”*, apresentado no congresso científico da Fatec Lins em novembro de 2024. A segunda frente concentrou-se no apoio à parte experimental do projeto de doutorado, com ênfase no desenvolvimento do algoritmo **DIFSAM – Diagnóstico Inteligente de Falhas em Sistemas Dinâmicos Utilizando Processamento de Sinais e Aprendizado de Máquina**. Trata-se de um modelo computacional robusto que combina técnicas de processamento digital de sinais, métodos estatísticos, redução de dimensionalidade, classificação automática e inteligência artificial, com o objetivo de identificar padrões vibracionais associados a falhas em sistemas físicos dinâmicos.

No nível da graduação, foram acompanhados pelo estagiário quatro projetos de Iniciação Científica, todos conduzidos por alunos do curso de Gestão da Qualidade da Fatec Lins:

- **Luiza Gabrielli da Monção Silva**, autora do projeto *“Avaliação Automatizada da Qualidade da Carne Bovina Utilizando Técnicas de Processamento de Imagem e Aprendizado de Máquina no Contexto do SGQ”*;
- **Marcela Vianna**, autora do projeto *“Aplicação do CEP na Gestão da Qualidade de Produtos Lácteos: Análise das Alterações Microbiológicas, Físico-Químicas e Sensoriais Durante o Shelf Life”*;
- **Leandro Ribeiro dos Santos**, autor do projeto *“Aplicação de Algoritmos Genéticos para a Correção de Medições de Espessuras na Galvanização: Soluções para a Variabilidade e Melhoria da Precisão”*;
- **Letícia de Souza Jacintho**, autora do projeto *“Análise Acústica de Ambientes Educacionais e Propostas de Melhorias Baseadas na ABNT NBR 10152:2017”*.

Todos os projetos contaram também com o acompanhamento do docente supervisor Prof. Dr. Fábio R. Chavarette o qual foram apresentados no congresso

acadêmico da Fatec Lins (<http://revista.fateclins.edu.br/congresso/sumario.xhtml>). O suporte técnico, metodológico e científico prestado pelo estagiário contribuiu para a formação integral dos estudantes. Essa atuação orientadora representou uma das atividades centrais do estágio, promovendo o amadurecimento científico dos discentes e consolidando a articulação entre ensino, pesquisa e aplicação tecnológica.

7. ATIVIDADES DIDÁTICAS DURANTE O ESTÁGIO

Durante o estágio de pós-doutorado, as atividades didáticas foram desempenhadas de forma integrada à rotina docente regular do estagiário, Prof. Dr. Roberto Outa, servidor efetivo da Faculdade de Tecnologia de Lins (Fatec Lins), vinculado ao curso superior de Tecnologia em Gestão da Qualidade. Atuando como professor concursado, o estagiário mantém jornada diária de 8 horas, lecionando disciplinas técnicas voltadas à área da qualidade, metrologia, estatística aplicada, análise de falhas, normalização e controle estatístico de processos, entre outras correlatas à temática do projeto de pesquisa. Além das atividades em sala de aula, o estagiário exerce função ativa como orientador de Trabalhos de Conclusão de Curso (TCC) e projetos de Iniciação Científica (IC), atualmente com um portfólio de aproximadamente 30 orientações em andamento. Tais trabalhos têm abordado temas aplicados e multidisciplinares, com forte aderência ao campo de análise e diagnóstico de falhas, modelagem de sistemas dinâmicos, algoritmos de aprendizado de máquina e métodos de simulação computacional, sempre articulando a prática docente com os eixos de pesquisa e inovação tecnológica.

O contato direto com os estudantes e a inserção permanente no ambiente acadêmico da Fatec Lins favoreceram a disseminação de conceitos e metodologias desenvolvidos no âmbito do estágio de pós-doutorado. As experiências de ensino possibilitaram a experimentação didática de conteúdos teóricos relacionados ao projeto, promovendo a construção de material pedagógico atualizado, a formulação de atividades práticas e a discussão de casos reais envolvendo aplicações industriais. Essas atividades reforçam o compromisso institucional do estagiário com a formação crítica e aplicada dos estudantes e evidenciam a relevância do ambiente da Fatec Lins como campo fértil para o desenvolvimento de pesquisas alinhadas às demandas do setor produtivo e aos avanços das tecnologias educacionais e científicas.

8. PLANO DE TRABALHO EXECUTADO E CRONOGRAMA CUMPRIDO.

As etapas previstas no plano de trabalho do estágio de pós-doutorado foram integralmente executadas, refletindo o comprometimento com a metodologia proposta e os objetivos definidos desde o início do projeto. O cronograma foi respeitado em sua totalidade, e os resultados alcançados superaram as expectativas iniciais quanto à aplicabilidade, inovação e contribuição científica.

No eixo **Estudos Iniciais e Adequação de Recursos**, foram realizadas revisões bibliográficas sistemáticas que consolidaram a base teórica do projeto. A Atividade 1.1 aprofundou os conceitos de Monitoramento da Integridade Estrutural (SHM), contextualizando o papel da análise de sinais vibracionais em sistemas físicos. A Atividade 1.2 tratou da modelagem matemática de processos inspirados em estudos sobre Alzheimer, com foco em sua estrutura dinâmica e aplicação computacional. A Atividade 1.3 abordou a consolidação de conhecimento sobre algoritmos Random Forest, suas vantagens em ambientes ruidosos e sua eficácia na classificação de padrões complexos.

Na fase de **Proposição, Aperfeiçoamento e Adaptações**, foi realizada a Atividade 2.1 com sucesso, estruturando a base de dados sintéticos e reais, e implementando métodos de simulação computacional que permitiram validar experimentalmente a estratégia proposta.

Durante a etapa de **Desenvolvimento**, a Atividade 3.1 foi cumprida com a implementação do algoritmo Random Forest aplicado a sinais de vibração simulados e tratados. Essa etapa incluiu a definição e o ajuste dos parâmetros do modelo, a realização de testes com diferentes cenários, e a avaliação do desempenho com métricas como acurácia, precisão, recall e F1-Score.

No módulo de **Extensões**, a Atividade 4.1 resultou na elaboração de versões complementares do algoritmo DIFSAM, com desdobramentos aplicáveis a outros domínios como bioprocessos, análise acústica e controle de qualidade industrial, demonstrando a versatilidade da metodologia.

Na fase final de **Avaliação**, foram cumpridas as Atividades 5.1 e 5.2. Os resultados foram apresentados no congresso científico da Fatec Lins e em sessões técnicas internas, e estão em fase final de submissão para periódico científico da área. O relatório técnico consolidado foi confeccionado com base nos dados computacionais, gráficos e análises estatísticas, e encontra-se pronto para avaliação institucional.

Em síntese, todas as etapas previstas no plano de trabalho foram executadas com rigor acadêmico e alinhamento às diretrizes propostas, validando a viabilidade técnica e científica do projeto e contribuindo significativamente para o avanço do conhecimento na área de diagnóstico inteligente de falhas em sistemas dinâmicos.

9. CONSIDERAÇÕES FINAIS

O estágio de Pós-Doutorado consolidou-se como uma jornada científica de elevada relevância acadêmica e tecnológica, cumprindo integralmente os objetivos estabelecidos e ampliando suas contribuições para além do escopo inicial. A proposta central, desenvolver um modelo matemático robusto para a detecção de falhas em sinais de vibração, foi concretizada por meio da formulação de uma estrutura computacional baseada em sistemas dinâmicos acoplados, inspirados no comportamento degenerativo associado à doença de Alzheimer, e integrados a algoritmos de aprendizado de máquina, com destaque para o Random Forest.

A principal inovação do projeto residiu na modelagem diferencial não linear de dois subsistemas interativos, representando dinâmicas acopladas com perturbações internas. A solução numérica, implementada via métodos de integração, gerou sinais simulados com e sem falhas, que foram posteriormente utilizados para treinar e testar classificadores Random Forest, com otimização de hiperparâmetros via busca em grade. Essa estrutura permitiu simular falhas com padrões complexos e realizar sua diferenciação por meio de estratégias computacionais interpretativas. A abordagem adotada representa uma transposição original de conceitos da neurodinâmica para o campo do diagnóstico de integridade estrutural e da vibração mecânica, proporcionando uma plataforma matemática versátil para a análise de sistemas físicos sujeitos a variações internas progressivas. Os testes realizados evidenciaram desempenho sólido do modelo, com métricas como acurácia, precisão, recall e F1-score superiores aos valores esperados em conjuntos de dados sintéticos ajustados.

A relevância do trabalho manifesta-se em quatro frentes principais:

- Na Medicina, o modelo oferece fundamentos para a simulação de interações neurais e para o desenvolvimento de métodos de análise de sinais biomédicos com comportamento oscilatório não estacionário, como eletroencefalogramas e eletromiogramas;
- Na Engenharia, contribui com novas estratégias para o monitoramento preditivo de falhas em sistemas vibratórios e estruturas críticas, reforçando as práticas do Monitoramento da Integridade Estrutural (SHM);
- Nos Bioprocessos, abre caminhos para a modelagem de instabilidades em reatores fermentativos, avaliação dinâmica de substratos bioativos e propagação de trincas em biomateriais com base em lógica bioinspirada;

- Na Bioquímica, o modelo matemático de acoplamento oferece uma base teórica para representar interações metabólicas entre vias regulatórias, osciladores bioquímicos e retroalimentações enzimáticas, podendo ser aplicado na simulação de respostas celulares a estímulos externos, no estudo de processos neurodegenerativos ou na dinâmica de cascatas moleculares envolvidas em estados patológicos complexos.

As atividades previstas no plano de trabalho foram conduzidas com rigor e profundidade, desde a fundamentação teórica até a implementação computacional e análise estatística dos resultados. Os dados processados permitiram avaliar, com elevada precisão, a separabilidade entre sinais com e sem falha, sustentando a consistência do modelo proposto. Além da contribuição técnica, o estágio teve papel importante na formação de recursos humanos, com orientação de projetos de Iniciação Científica e colaboração ativa com alunos de Doutorado, promovendo a integração entre ensino, pesquisa e inovação. Os resultados foram divulgados em evento científico e estão em processo de publicação, evidenciando o compromisso com a difusão do conhecimento e a continuidade das investigações. O caráter transdisciplinar do projeto foi adotado não apenas pela convergência entre áreas distintas, mas pela integração conceitual e metodológica entre elas. A modelagem inspirada em processos degenerativos próprios da neurociência foi aplicada à engenharia, aos bioprocessos e à bioquímica por meio de uma lógica computacional unificada. Ao contrário de uma abordagem multidisciplinar, na qual os conhecimentos atuam paralelamente, a transdisciplinaridade aqui estabeleceu uma nova base comum entre os campos, promovendo a síntese de saberes e a criação de soluções adaptáveis a múltiplos contextos.

Em síntese, este projeto de pós-doutorado estruturou uma linha de pesquisa inovadora, transdisciplinar e de amplo potencial de aplicação, alicerçada na fusão entre modelagem matemática, análise de sinais e inteligência computacional. Suas contribuições se estendem da engenharia à medicina, da bioquímica à biotecnologia, com perspectivas concretas de impacto na ciência aplicada, na indústria e na saúde.

10. REFERÊNCIAS

- ARÉVALO, L. A.; ANTONOVA, O.; O'BRIEN, S. A.; SINGH, G. P.; SEIFERT, A.. Detection of Alzheimer's by Machine Learning-assisted Vibrational Spectroscopy in Human Cerebrospinal Fluid. **Journal of Physics: Conference Series**, v. 2407, p. 1-7, 2022. DOI: 10.1088/1742-6596/2407/1/012026.
- BHOWMIK, B.; PAKRASHI, V.; HAZRA, B.. **Real-Time Structural Health Monitoring of Vibrating Systems**. Boca Raton: CRC Press, 2022. 249p.
- BREIMAN, L. Bagging Predictors. **Machine Learning**, v. 24, n. 2, p. 123-140, 1996.
- BREIMAN, L. Random Forests. **Machine Learning**, v. 45, n. 1, p. 5-32, 2001.
- DOEBLING, Scott W.; FARRAR, Charles R. **Damage Identification and Health Monitoring of Structural and Mechanical Systems**. 1st ed. Los Alamos: Los Alamos National Laboratory, 1998.
- HAO, W., FRIEDMAN, A., Mathematical model on Alzheimer's disease, **BMC Systems Biology**, v.10, n.108, 1-18p. 2016. DOI 10.1186/s12918-016-0348-2.
- HAO, W.; FRIEDMAN, A.. Mathematical model on Alzheimer's disease. **BMC Systems Biology**, v. 10, n. 108, 2016. DOI: 10.1186/s12918-016-0348-2.
- HASTIE, T.; TIBSHIRANI, R.; FRIEDMAN, J. **The Elements of Statistical Learning: Data Mining, Inference, and Prediction**. 2nd Edition. Springer, 2009.
- INGENIEROS, Luis G.; OLMOS, Xavier. **Health Monitoring of Bridges and Buildings**. 1st ed. New York: Springer, 2003.
- JAMES, G.; WITTEN, D.; HASTIE, T.; TIBSHIRANI, R. **An Introduction to Statistical Learning: with Applications in R**. Springer, 2013.
- KINSLER, L. E.; FREY, A. R.; COPPENS, A. B.; SANDERS, J. V. **Fundamentals of acoustics**. 4. ed. Hoboken: John Wiley & Sons, 1999. 548 p.
- KUTOR, J. K.; AGEDE, P.; ALI, R. H.. Maintenance Practice, Causes of Failure and Risk Assessment of Diagnostic Medical Equipment. **Journal of Biomedical Engineering and Medical Devices**, v. 2, n. 1, p. 123, 2017. DOI: <https://doi.org/10.4172/2475-7586.1000123>.
- LI, J. ; MAO, Y.; ZHANG, J.. Maintenance and quality control of medical equipment based on information fusion technology. **Computational Intelligence and Neuroscience**, v. 2022, p. 1-11, 2022. DOI: <https://doi.org/10.1155/2022/9333328>.
- LIAW, A.; WIENER, M. Classification and Regression by Random Forest. **R News**, v. 2, n. 3, p. 18-22, 2002.

MONTEIRO, F.; SOTIROPOULOS, I.; CARVALHO, O.; SOUSA, N.; SILVA, F. S. Multi-mechanical waves against Alzheimer's disease pathology: a systematic review. **Translational Neurodegeneration**, v. 10, n. 36, p. 1-28, 2021. DOI: 10.1186/s40035-021-00256-z.

PERNECZKY, R., **Biomarkers for Alzheimer's Disease Drug Development**, 2 ed., Springer Nature, 2024. 344p.

ROY, K., **Computational Modeling of Drugs Against Alzheimer's Disease**, 2 ed., Springer Science+Business Media, New York, 2023. 492p.

SAHYOUNI, R., BROWN, N., CHEN, J., **Alzheimer's Disease decoded: The History, Present, and Future of Alzheimer's Disease and Dementia**, 2 ed., World Scientific Publishing, Danvers, 2022. 426p.

WILLSON, K.; ISON, K.; TABAKOV, S.. **Medical Equipment Management**. Boca Raton: CRC Press, 2013. 334p.

WORDEN, Keith; BALAGEAS, Daniel. **The Handbook of Structural Health Monitoring**. 1st ed. London: John Wiley & Sons, 2007.