



UNIVERSIDADE FEDERAL DO CEARÁ
CENTRO DE TECNOLOGIA
DEPARTAMENTO DE ENGENHARIA MECÂNICA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA MECÂNICA

JUAREZ POMPEU DE AMORIM NETO

MODELAGEM NUMÉRICA E EXPERIMENTAL DE UMA "PAREDE SOLAR"
UTILIZANDO NANOFLUIDOS DE PRATA E DIÓXIDO DE TITÂNIO

FORTALEZA

2020

JUAREZ POMPEU DE AMORIM NETO

MODELAGEM NUMÉRICA E EXPERIMENTAL DE UMA "PAREDE SOLAR"
UTILIZANDO NANOFLUIDOS DE PRATA E DIÓXIDO DE TITÂNIO

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Mecânica da Universidade Federal do Ceará, como requisito à obtenção do título de Mestre em Engenharia Mecânica. Área de concentração: Energias Renováveis.

Orientador: Prof. Dr. Paulo Alexandre Costa Rocha.

FORTALEZA

2020

Dados Internacionais de Catalogação na Publicação
Universidade Federal do Ceará
Biblioteca Universitária
Gerada automaticamente pelo módulo Catalog, mediante os dados fornecidos pelo(a) autor(a)

A543m Amorim Neto, Juarez Pompeu de.
Modelagem numérica e experimental de uma "parede solar" utilizando nanofluidos de prata e dióxido de titânio / Juarez Pompeu de Amorim Neto. – 2020.
56 f. : il. color.

Dissertação (mestrado) – Universidade Federal do Ceará, Centro de Tecnologia, Programa de Pós-Graduação em Engenharia Mecânica, Fortaleza, 2020.
Orientação: Prof. Dr. Paulo Alexandre Costa Rocha.

1. Parede Solar. 2. Aprendizagem de Máquina. 3. Nanofluido. I. Título.

CDD 620.1

JUAREZ POMPEU DE AMORIM NETO

MODELAGEM NUMÉRICA E EXPERIMENTAL DE UMA "PAREDE SOLAR"
UTILIZANDO NANOFUIDOS DE PRATA E DIÓXIDO DE TITÂNIO

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Mecânica da Universidade Federal do Ceará, como requisito parcial à obtenção do título de Mestre em Engenharia Mecânica. Área de concentração: Energias Renováveis.

Aprovada em: 21/04/2020.

BANCA EXAMINADORA

Prof. Dr. Paulo Alexandre Costa Rocha (Orientador)
Universidade Federal do Ceará (UFC)

Prof. Dr. André Valente Bueno
Universidade Federal do Ceará (UFC)

Prof. Dr. Matheus Pereira Porto
Universidade Federal de Minas Gerais (UFMG)

A Deus.

Aos meus pais, Lleni e Cleone.

AGRADECIMENTOS

Ao Prof. Dr. Paulo Alexandre Costa Rocha, pela excelente orientação e ao Prof. Dr. Ricardo José Pontes Lima pelos ensinamentos e condução desse trabalho.

A Deus, a minha mãe, a minha vó, à banca e aos amigos de mestrado.

Minha mulher por apoiar desde o início

À Bianca por se fazer presente.

Aos professores participantes da banca examinadora André Valente Bueno e Matheus Pereira Porto pelo tempo, pelas valiosas colaborações e sugestões.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

“Um momento de dor vale uma vida inteira de glória.”

(Louis Zamperini)

RESUMO

A população mundial está cada vez mais atenta com as questões ambientais que envolvem nosso planeta. Em busca de soluções que venham contribuir para conservação do meio ambiente está o uso das energias renováveis, que estão em grande expansão. O uso da energia solar é uma solução para a conservação ambiental, onde a mesma é objeto de estudo desse trabalho. O trabalho teve como objetivo avaliar a capacidade de armazenamento de energia dos nanofluidos de prata, dióxido de titânio e o nanofluido híbrido composto pela aglomeração das duas nanopartículas utilizados para absorção solar direta em uma “Parede Solar”. Além disso, esse trabalho propõe a verificação da aplicação dos modelos de aprendizagem de máquina K-vizinhos mais próximos, Regressão de Vetor Suporte e Florestas Aleatórias para predição da temperatura da água na parede solar. Os experimentos realizados foram expostos por um período de 16 horas por vários dias, onde foram testadas diversas concentrações para análise. Uma das análises desse trabalho consistiu no acompanhamento do perfil de temperatura, onde a prata obteve os melhores resultados, conseguindo um ganho de 26% contra 5% do dióxido de titânio. A taxa de energia armazenada (SER) também foi analisada, onde o aumento dessa taxa se dava nas primeiras horas do dia, tanto para a prata como para o titânio. Essa taxa também foi analisada em função da concentração, onde uma maior concentração representava maiores valores de SER. A taxa de absorção específica (SAR) também foi avaliada, onde se obteve para a mesma um comportamento inversamente proporcional ao da SER, sendo necessária uma análise conjunta para se obter a concentração ideal de cada nanofluido. A prata obteve melhorias contínuas com o aumento das concentrações, sendo necessários mais experimentos para se chegar na concentração ideal. Já o titânio mostrou uma estabilidade para SER e SAR em uma concentração de 1,45 ppm, sendo a concentração considerada ideal. O nanofluido híbrido foi analisado de forma semelhante, obtendo uma fração molar ideal de 6%, que corresponde a uma concentração de prata de 0,8125 ppm e 23,2 ppm do titânio. Na modelagem numérica os dados foram separados em conjuntos de treino e teste, onde o objetivo era identificar os menores erros na fase de teste, e assim as Florestas Aleatórias conseguiram os melhores resultados, obtendo um RMSE de 0,562°C. Já os métodos SVR e KNN obtiveram taxas de erros ligeiramente maiores, sendo de 0,818°C e 0,857°C respectivamente. A modelagem numérica conseguiu estabelecer uma abordagem que conseguiu atender ao objetivo de previsão de temperatura da Parede Solar, predizendo valores bem próximos dos medidos, com taxas de erros inferiores a 1°C.

Palavras-chave: Parede Solar. Aprendizagem de Máquina. Nanofluido.

ABSTRACT

The world population is increasingly aware of the environmental issues surrounding our planet. In the search for solutions that will contribute to the preservation of the environment is the use of renewable energies, which are in a great expansion process. The use of solar energy is a solution for environmental preservation, which is the subject of this work. The work aimed to evaluate the energy absorption capacity of silver and titanium dioxide nanofluids and the hybrid nanofluid composed by the agglomeration of the two nanoparticles used for direct solar absorption in a "Solar Wall". In addition, this work proposes the verification of the application of the learning models of the nearest K-neighbor machine, Support Vector Machine and Random Forests to predict the water temperature in the solar wall. The experiments were exposed for a period of 16 hours over several days, where different concentrations were tested for analysis. One of the analyzes of this work consisted of monitoring the temperature profile, where silver obtained the best results, achieving a gain of 26% against 5% of titanium dioxide. The stored energy rate (SER) was also analyzed, where the increase in this rate occurred in the early hours of the day, for both silver and titanium. This rate was also analyzed as a function of concentration, where a higher concentration represented higher SER values. The specific absorption rate (SAR) was also evaluated, where a behavior inversely proportional to that of SER was obtained, requiring a joint analysis to obtain the ideal concentration of each nanofluid. The silver obtained continuous improvements with the increase of the concentrations, being necessary more experiments to reach the ideal concentration. Titanium, on the other hand, showed a stability for SER and SAR at a concentration of 1.45 ppm, the concentration being considered ideal. The hybrid nanofluid was analyzed in a similar way, obtaining an ideal molar fraction of 6%, which corresponds to a silver concentration of 0.8125 ppm and 23.2 ppm of titanium. In numerical modeling the data were separated into training and test sets, where the purpose was to identify the smallest errors in the test phase, and thus the Random Forest achieved the best results, obtaining an RMSE of 0.562°C. The SVR and KNN methods obtained slightly higher error rates, being 0.818°C and 0.857°C respectively. The numerical modeling was able to establish an approach that was able to meet the objective of forecasting the temperature of the Solar Wall, predicting values very close to those measured, with error rates below 1°C

Keywords: Solar Wall. Machine Learning. Nanofluid.

LISTA DE FIGURAS

Figura 1 - Sistema solar de absorção direta.....	20
Figura 2 - Aparato solar por absorção direta	21
Figura 3 - Coletor solar de tubo evacuado por termossifão com simulador solar	22
Figura 4 - Tubos de vidro para análise do nanofluido.....	23
Figura 5 - Parede Solar.....	24
Figura 6 - Parede Solar para testes e coleta de dados.	25
Figura 7 - Passos do experimento de acordo com a incidência solar.....	25
Figura 8 - Separação do conjunto de dados de treino e teste para predição da temperatura do fluido.....	28
Figura 9 - Árvore de regressão.	30
Figura 10 - Análise de correlação dos preditores.....	50

LISTA DE GRÁFICOS

Gráfico 1	- Ganho de temperatura do nanofluido de prata em relação à água.	33
Gráfico 2	- Taxa de energia armazenada dos nanofluidos para diversas concentrações.	34
Gráfico 3	- Máxima taxa de energia absorvida em função da concentração.	35
Gráfico 4	- Taxa de absorção específica por unidade de massa em função da concentração de nanopartículas de prata.	36
Gráfico 5	- Ganho de temperatura do nanofluido de dióxido de titânio (TiO ₂) em relação à água.	37
Gráfico 6	- Taxa de energia armazenada pelas nanopartículas de dióxido de titânio.	37
Gráfico 7	- SER máxima em função da concentração.	38
Gráfico 8	- Variação de SAR em função da concentração (TiO ₂).	39
Gráfico 9	- Variação de temperatura do fluido híbrido.	41
Gráfico 10	- Taxa de energia armazenada para o nanofluido híbrido (Prata – TiO ₂).	43
Gráfico 11	- Razão de energia absorvida em função da concentração de prata no dióxido de titânio.	43
Gráfico 12	- Variação de SAR em função da fração molar do nanofluido híbrido.	44
Gráfico 13	- Comparação entre os valores medidos experimentalmente para a água e os valores calculados pelo método SVR.	46
Gráfico 14	- Comparação entre os valores medidos experimentalmente e os valores calculados pelo método Florestas Aleatórias.	47
Gráfico 15	- Escolha do número de vizinhos baseado nas métricas de erros.	48
Gráfico 16	- Comparação entre os valores medidos experimentalmente para a água e os valores calculados pelo método KNN.	48

LISTA DE TABELAS

Tabela 1 - Concentração molar e em volume dos nanofluidos de prata e dióxido de titânio...	26
Tabela 2 - Comparativo entre nanofluidos híbridos e isolados.	42
Tabela 3 - Resultados de SVR – Seleção dos hiperparâmetros em função das métricas de erro.	45
Tabela 4 - Resultados de Florestas Aleatórias – Seleção dos hiperparâmetros de acordo com as métricas de erro.....	47
Tabela 5 - Resultados dos conjuntos de teste e treinamento (água).....	49

LISTA DE ABREVIATURAS E SIGLAS

KNN	K- Vizinhos mais próximos
RF	Florestas Aleatórias
SAR	Taxa de Absorção Específica
SER	Taxa de Energia Armazenada
SVR	Regressão de Vetor Suporte

SUMÁRIO

1	INTRODUÇÃO	15
2	REFERENCIAL TEÓRICO	17
2.1	Síntese dos nanofluidos	17
2.2	Condutividade térmica	18
2.3	Viscosidade	18
2.4	Calor específico	19
2.5	Aplicações.....	19
3	MATERIAIS E MÉTODOS	23
3.1	Configuração Experimental	23
3.2	Aquisição de dados.....	24
3.3	Concentrações estudadas	25
3.4	Preparação dos nanofluidos.....	26
3.5	Taxa de absorção específica (SAR) e Taxa de energia armazenada (SER)	26
4	MODELAGEM NUMÉRICA	28
4.1	Regressão de Vetor Suporte (SVR).....	28
4.2	Florestas Aleatórias - Random Forests (RF).....	30
4.3	K - Vizinhos mais próximos (KNN).....	31
4.4	Métricas para análise de previsão de temperatura.....	31
5	RESULTADOS E DISCUSSÕES	32
5.1	Resultados experimentais	32
5.1.1	<i>Resultados experimentais para o nanofluido de prata</i>	32
5.1.2	<i>Resultados experimentais para o nanofluido de dióxido de titânio (TiO₂)</i>	36
5.1.3	<i>Análise de SER e SAR para os nanofluidos de prata e dióxido de titânio</i>	39
5.1.4	<i>Resultados experimentais para o nanofluido híbrido</i>	40
5.1.5	<i>Análise de SER para o nanofluido híbrido</i>	42
5.2	Análise numérica	44
5.2.1	<i>Resultados do SVR</i>	45
5.2.2	<i>Resultados do RF</i>	46
5.2.3	<i>Resultados do KNN</i>	47
5.2.4	<i>Resultados do conjunto de teste</i>	49

<i>5.2.5 Análise dos preditores</i>	49
6 CONCLUSÃO	51
REFERÊNCIAS	54

1 INTRODUÇÃO

A importância dada ao meio ambiente gerou uma grande preocupação com as questões ambientais que envolvem a população mundial, já que existe uma alta degradação em virtude do uso de combustíveis fósseis. A geração de energia proveniente de fontes convencionais causou uma degradação ambiental que pode ser vista através de poluição, chuva ácida, aquecimento global, etc. (SUMAN; KHAN; PATHAK, 2015). Em virtude desse problema, a busca por energias renováveis vem aumentando significativamente nos últimos anos, onde tem sido um objeto de estudo por cientistas e profissionais (BAZDIDI-TEHRANI; KHABAZIPUR; VASEFI, 2018). A energia solar é uma das fontes renováveis que contribuem para a conservação do meio ambiente, sendo ela uma das principais fontes de energia renováveis, onde seu campo de aplicação pode ser para conversão direta em energia elétrica ou aproveitar a mesma para aquecimento de fluidos, tanto em uso doméstico como em uso industrial (acionamento de uma turbina).

O aproveitamento de energia térmica para aquecimento de água se dá por meio do uso de coletores solares, onde a eficiência de um coletor é um parâmetro de estudo muitas vezes limitado (BANDARRA FILHO *et al.*, 2014). O processo de aquecimento em coletores solares tradicionais não é tão eficiente devido à existência de resistências térmicas no processo, onde o conceito de absorção direta da radiação solar promete aumentar a capacidade de absorção e assim reduzir as perdas térmicas para o ambiente (BEICKER *et al.*, 2018). Da mesma forma, os fluidos convencionais que são utilizados nos coletores solares também contribuem para uma eficiência limitada, e assim o uso de nanofluidos pode ser indicado para solucionar esse tipo de problema (EBRAHIMI-MOGHADAM *et al.*, 2018). Nanofluidos são nanopartículas com variação de tamanho (1 – 100 nm) que são dispersas em um fluido base. As nanopartículas podem ser de diversos materiais, tais como metais, não metais, óxidos, carbonetos, misturas de nanopartículas (fluidos híbridos), etc. Por causa do seu pequeno tamanho, o uso do nanofluidos se torna vantajoso quando se pensa em absorção de calor, e assim as perdas em coletores solares podem ser reduzidas (MEHRALI *et al.*, 2015).

Além do tipo de nanofluido, outra melhoria pode ser encontrada quando se varia a concentração de nanopartículas no fluido base, resultando em uma conversão fototérmica diferente e assim a eficiência de um coletor solar fica diretamente relacionada com a concentração de nanopartículas (OZSOY e CORUMLU, 2018). Nem sempre o aumento da concentração implica em resultados satisfatórios, podendo haver algumas limitações (SREEKUMAR *et al.*, 2019), tais como os custos, processo de síntese demorado, menor

estabilidade e maior viscosidade, onde a estabilidade tem um impacto direto na absorção óptica. Em virtude disso, é de extrema importância o cálculo de um parâmetro de eficiência de conversão fototérmica, que é a taxa de absorção específica (SAR), em conjunto com a taxa de energia armazenada (SER), que após definidos, seleciona-se a concentração ideal de trabalho.

O recurso solar pode ser altamente variável e devido à presença de nuvens, gases e outros fatores naturais. Devido a essa variação, problemas relacionados à produção e confiabilidade de sistemas solares podem existir. O aprendizado de máquina, que é um dos ramos da ciência da computação pode auxiliar na resolução desse problema, onde ele possui como vantagem a possibilidade de fornecer soluções relacionadas aos reconhecimentos de padrões, encontrando relações entre variáveis de entrada e saída, tornando possível a previsão de dados desconhecidos em função do histórico de dados analisados (VOYANT *et al.*, 2017).

O presente trabalho tem por objetivo a avaliação de três nanofluidos, produzidos com prata e dióxido de titânio (TiO_2), assim como o nanofluido híbrido formado pela aglomeração desses dois. O trabalho busca identificar o quanto cada nanofluido obteve de ganho de temperatura com relação à água, bem como descobrir a concentração ideal de trabalho de cada um. Além da análise experimental, esse trabalho visa comparar o desempenho de três métodos de aprendizagem de máquina, o Random Forest (RF) e o Suport Vector Regression (SVR) na regressão de temperatura do fluido de trabalho de um experimento solar denominado “Parede Solar”.

2 REFERENCIAL TEÓRICO

Nanofluidos já vem sendo estudado por muito pesquisadores e apresentaram resultados superiores ao do fluido base, como já foi mencionado. Os nanofluidos são formados por diversos tipos de materiais, tais como os metais, óxidos, nanotubos de carbono e outros, e os nanofluidos conseguem superar o fluido base devido à alta condutividade térmica desses materiais, sendo um fluido com grande potencial de transferência de calor (BEICKER *et al.*, 2018).

O uso de partículas nanométricas traz melhorias, pois o seu tamanho pequeno aumenta a superfície de contato e conseqüentemente aumenta a troca de calor, já condutividade térmica pode ir se ajustando quando a concentração é variada (CHOI *et al.*, 1995).

Trabalhos recentes mostraram que o uso de nanofluidos vêm sendo aperfeiçoado e melhorado cada vez mais o seu uso em coletores solares, como os de prata em Ozsoy e Corumlu (2018), que melhoraram em 40% a eficiência de um coletor solar de tubo evacuado por temossifão, os de TiO_2 em Bazdidi-tehrani, Khabazipur e Vasefi (2018) que melhoraram em 10% a eficiência de um coletor solar de placas planas com nervuras, os de CeO_2 , que aumentaram em 37,3% a temperatura do nanofluido com relação à água em Sharafeldin e Gróf (2018), os nanotubos de carbono foram usados em Mahbubul *et al.* (2018) e mostraram uma melhoria de 66% na eficiência de um coletor solar de tubo evacuado, assim como o óxido de zinco, que foi utilizado em Kaya, Arslan e Eltugral (2018), mostrando uma melhoria de 62,87% na eficiência de um coletor solar evacuado de tubo em U. Uma variação de nanofluidos também vem sendo analisada, eles são conhecidos como nanofluidos híbridos, pois são formados pela aglomeração de duas ou mais nanopartículas visando o uso das melhores propriedades de cada uma. O óxido de grafeno e o ouro formaram uma solução híbrida e melhoraram a eficiência de geração de vapor em 10,8% (FU *et al.*, 2017), o nanofluido híbrido de alumina-cobre melhorou em 12,11% a condutividade térmica (SURESH *et al.*, 2011) e Karami (2018) mostrou que o uso do nanofluido híbrido Fe_3O_4/SiO_2 aprimorou a eficiência de um coletor solar em 21,7%.

2.1 Síntese dos nanofluidos

A preparação dos nanofluidos acaba sendo um fator importante, pois durante a obtenção desses nanofluidos podem haver aglomerações ou “*Clusters*” ocorrendo assim a precipitação dos nanofluidos e implicando negativamente nos resultados requeridos.

Existem dois métodos de preparação dos nanofluidos: método de um passo e dois passos. A técnica de um passo combina a produção das nanopartículas e as nanopartículas dispersas no fluido através de um único passo. Esse método reduz os efeitos da aglomeração de nanopartículas tornando o fluido mais estável, porém o custo se torna elevado.

O método de dois passos consiste na produção de nanopartículas em pó seco e depois a dispersão no fluido base. Esse método apresenta uma maior chance de aglomeração de nanopartículas, mas apresenta um custo inferior ao método de um passo.

2.2 Condutividade térmica

Com a inserção de nanopartículas no fluido base, as propriedades térmicas são alteradas, consequentemente a transferência de calor é alterada e por isso a condutividade térmica acaba sendo uma propriedade muito importante para os estudos sobre os nanofluidos. Alguns pesquisadores já viram que os nanofluidos possuem condutividade térmica maiores que as do fluido base (SURESH *et al.*, 2011; BUONOMO *et al.*, 2015; KHEDKAR *et al.*, 2016).

Alguns parâmetros são responsáveis pela condutividade térmica do nanofluido, dentre eles podemos citar a concentração de nanopartículas, tamanho e forma das nanopartículas, temperatura, aditivos e acidez (OLIVEIRA, 2012).

A concentração de nanopartículas, temperatura e acidez possui uma relação diretamente proporcional com a condutividade térmica, já o tamanho das nanopartículas possui uma relação inversamente proporcional com a condutividade térmica.

2.3 Viscosidade

A viscosidade é a medida de resistência ao escoamento que um fluido vai ter. No estudo dos nanofluidos, a viscosidade está relacionada com a concentração de nanopartículas, onde uma maior concentração implica em uma maior viscosidade. A viscosidade pode ser medida com diversos equipamentos, dentre eles pode-se citar:

- Viscosímetro de pistão: possui um pistão que se move por meio de um campo magnético, onde o período de oscilação é diretamente proporcional a viscosidade do fluido para uma certa intensidade de campo magnético.
- Viscosímetro Rotacional: a viscosidade é medida através da velocidade angular de uma parte móvel que é imersa no fluido.

- Viscosímetro capilar: calcula o tempo que o fluido leva para escoar através de um tubo capilar, onde esse tempo é proporcional a viscosidade cinemática.

2.4 Calor específico

O calor específico mede a quantidade de calor necessário para que uma substância tenha sua temperatura elevada, por isso o calor específico do nanofluido também é outra característica muito importante nesse estudo, já que na maioria dos casos as nanopartículas possuem calor específico menor que o do fluido base, contribuindo assim para uma maior capacidade de absorção de calor.

Shin e Banerjee (2010) utilizou nanopartículas de sílica dispersas em uma mistura eutética de carbonato de lítio e carbonato de potássio, conseguindo um aumento no calor específico de 19 – 24%. As medições de Shin e Banerjee (2010) foi realizada por um calorímetro de varredura diferencial.

Wole-osho *et al.* (2020) fez uma análise de nanofluidos híbridos de Al_2O_3 – ZnO e verificou uma redução máxima no calor específico de 30,12%.

Os modelos experimentais geralmente são comparados com modelos teóricos como o modelo expresso por Pak e Cho (1998):

$$c_{p_{nf}} = \phi(c_p)_p + (1 - \phi)(c_p)_f \quad (1)$$

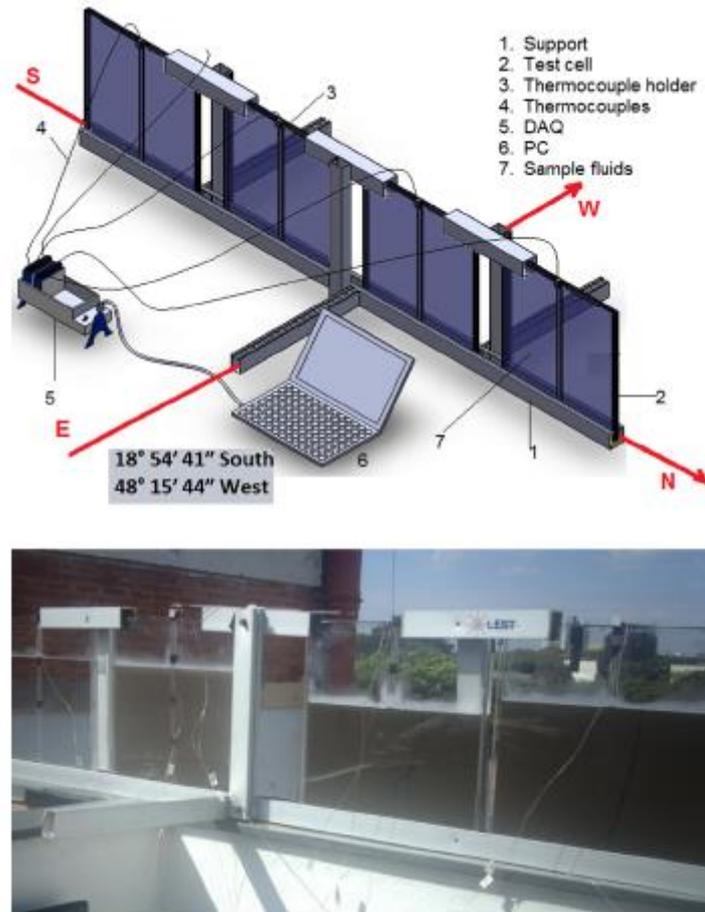
Onde c_p é o calor específico, ρ é a densidade e ϕ é a fração volumétrica de nanopartículas. Os subscritos nf , p e f se referem ao nanofluido, nanopartícula e fluido base respectivamente.

2.5 Aplicações

Estudos sobre energia solar vem aumentando ultimamente, principalmente para aumentar a eficiência no uso de coletores solares. Paralelamente, o estudo dos nanofluidos vem ganhando força no ramo científico, onde esses nanofluidos vem aprimorando o uso em sistemas solares térmicos.

Bandarra Filho *et al.* (2014) investigou experimentalmente as características de conversão fototérmica dos nanofluidos de prata utilizando um sistema solar térmico de absorção direta, conforme a Figura 1. Os resultados mostraram que a prata tem uma ótima capacidade de conversão fototérmica, onde ele conseguiu um aumento de 144% na energia armazenada para uma concentração de nanopartículas de 6,5 ppm.

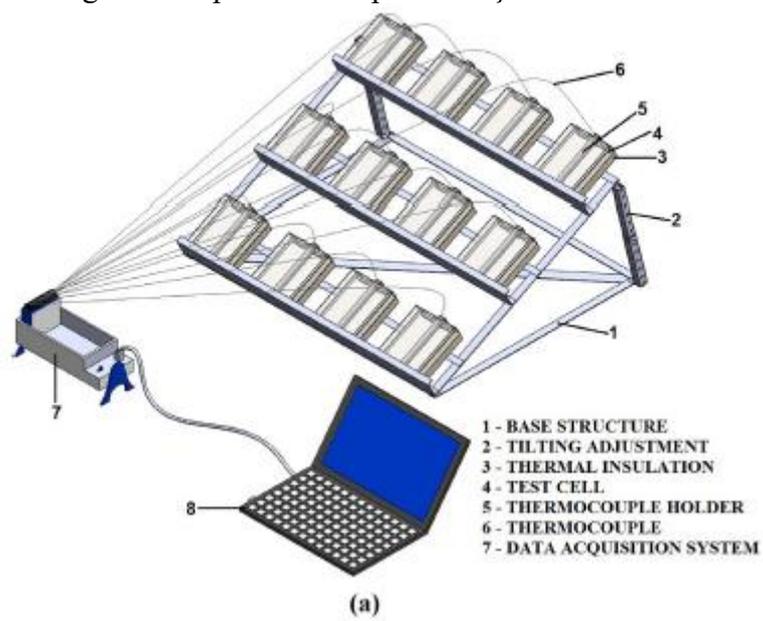
Figura 1 - Sistema solar de absorção direta



Fonte: Bandarra Filho *et al.* (2014).

Beicker *et al.* (2018) investigou de forma experimental a conversão fototérmica dos nanofluidos de ouro e MWCNT, ambos em água. Os resultados mostraram que os nanofluidos obtiveram ótima capacidade de conversão fototérmica, onde a taxa de absorção específica por unidade de massa (SAR) teve um decaimento com o aumento da concentração e a taxa de energia armazenada obteve um aumento conforme a concentração de nanopartículas aumentava, mostrando assim que para os nanofluidos estudados se conseguia chegar em uma concentração ideal de trabalho. A Figura 2 mostra a modelagem experimental desse trabalho.

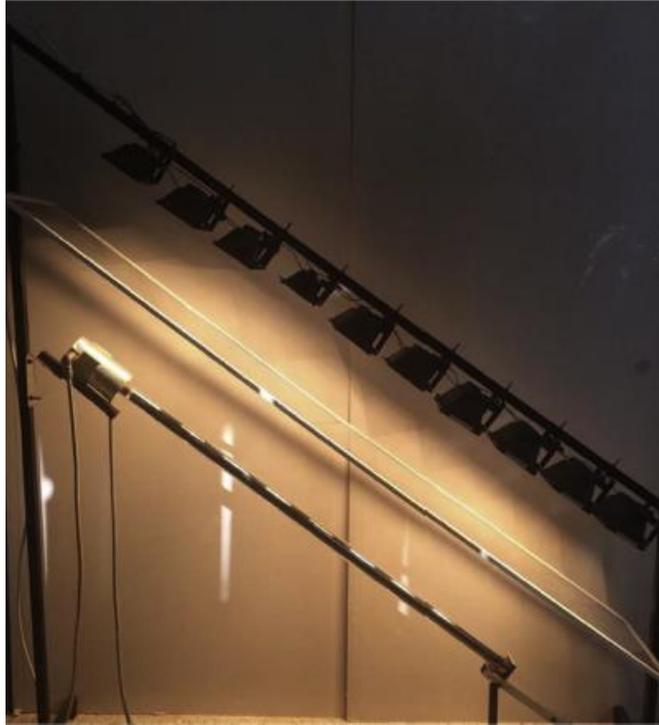
Figura 2 - Aparato solar por absorção direta



Fonte: Beicker *et al.* (2018).

Ozsoy e Corumlu (2018) realizaram um estudo experimental para determinar a eficiência térmica de um coletor solar de tubo evacuado por termossifão (THP), como na Figura 3, usando nanofluido de prata em água. O uso desse nanofluido aumentou a eficiência desse coletor em 40%.

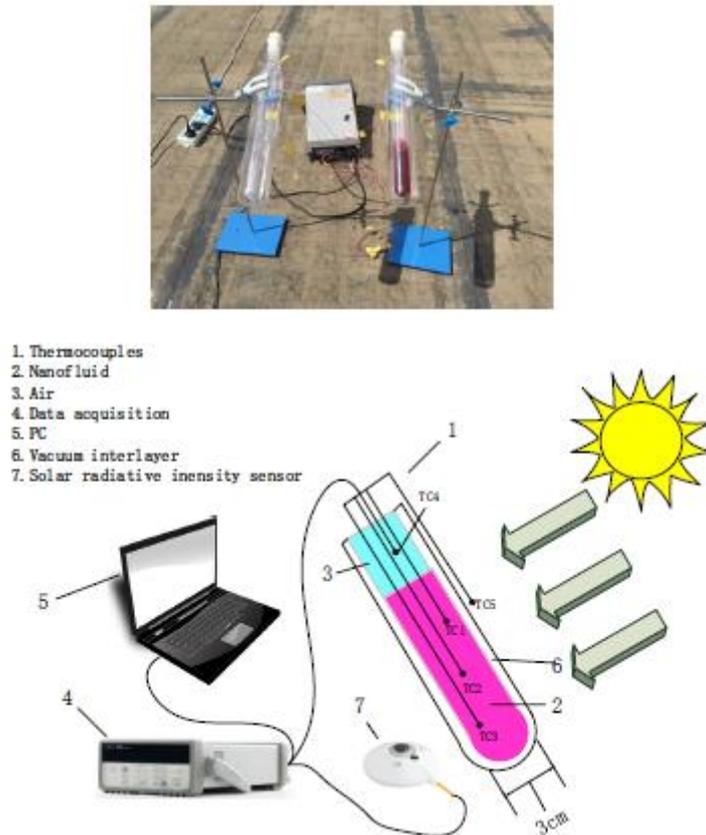
Figura 3 - Coletor solar de tubo evacuado por termossifão com simulador solar



Fonte: Ozsoy e Corumlu (2018).

Jin *et al.* (2016) avaliou experimentalmente a eficiência de conversão fototérmica dos nanofluidos de ouro em um tubo de cilindro de vidro de quartzo resistente a altas temperaturas. O tubo continha uma camada a vácuo para que dessa forma fosse evitada as perdas por convecção, conforme a Figura 4. Além da análise experimental, foi feita uma análise numérica para calcular a eficiência de absorção solar sem que haja conhecimento do campo de temperatura dos nanofluidos.

Figura 4 - Tubos de vidro para análise do nanofluido



Fonte: Jin *et al.* (2016).

3 MATERIAIS E MÉTODOS

3.1 Configuração Experimental

Um aparato denominado “Parede Solar”, como em Amorim Neto *et al.* (2019), foi construído para atender os objetivos de pesquisa, onde o mesmo apresenta uma estrutura de alumínio com quatro placas de vidro na célula inferior (duas internas e duas externas) e mais quatro na célula superior, de forma análoga. Os vidros externos foram colocados para que fossem reduzidas as perdas por convecção. Os vidros externos possuem 4 mm de espessura, 8 mm de espessura para os vidros internos, comprimento de 1000 mm e altura de 500 mm.

Na célula inferior do experimento foi inserida água destilada na quantidade de 3,5 L e na célula superior foi inserido o nanofluido de estudo também no mesmo volume. A distância entre os vidros que comportavam os fluidos era de 7 mm. A figura 5 detalha a Parede Solar.

Figura 5 - Parede Solar

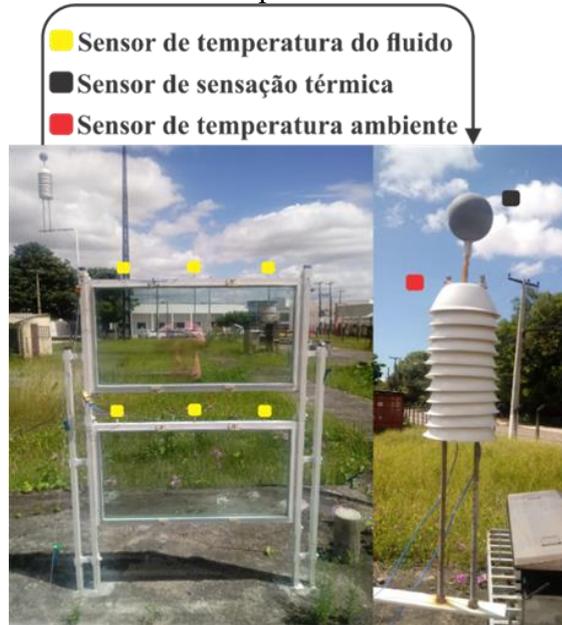


Fonte: Autorial própria.

3.2 Aquisição de dados

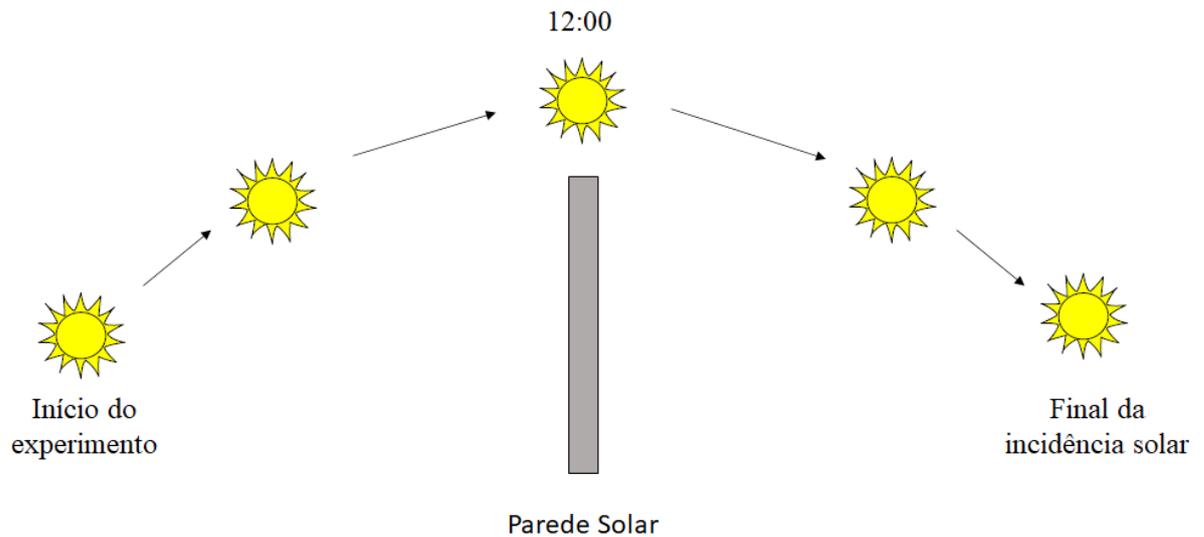
Para aferição das temperaturas dos fluidos foram utilizados 6 termopares do tipo K com precisão de $0,1^{\circ}\text{C}$, frequência de 1 Hz e calibração em banho termostático contra um termômetro de vidro, onde três foram colocados na célula inferior e mais três na superior, conforma a coloração amarela na Figura 6. Além da temperatura dos fluidos, foram coletadas as temperaturas ambiente e de sensação térmica, onde também foram usados sensores do tipo K com mesma precisão, conforma a coloração vermelha e preta na Figura 6. Para aquisição dos dados foi usado um *Datalogger* modelo RX12 OMEGA. Os experimentos foram realizados no Laboratório de Energia Solar e Gás Natural (LESGN) da Universidade Federal do Ceará na cidade de Fortaleza (Latitude: $03^{\circ} 43' 02''$ Sul, Longitude: $38^{\circ} 32' 35''$ Oeste) entre os dias 20/06/2019 e 16/10/2019 no período de 5:30 até 21:30, já que nesse intervalo de tempo ainda se conseguia verificar um diferencial de temperatura do nanofluido em comparação com a água destilada. O experimento tinha uma de suas faces voltadas para leste e outra para oeste, de tal forma que o aproveitamento da radiação solar fosse aproveitado antes e depois de 12:00, conforme Figura 7.

Figura 6 - Parede Solar para testes e coleta de dados.



Fonte: Autoria própria.

Figura 7 - Passos do experimento de acordo com a incidência solar



Fonte: Autoria própria.

3.3 Concentrações estudadas

Os nanofluidos testados são compostos de nanopartículas de prata e de TiO_2 nas concentrações, conforme a Tabela 1:

Tabela 1 - Concentração molar e em volume dos nanofluidos de prata e dióxido de titânio

Nanofluidos	Concentração Molar (mol/L)	Concentração em volume (ppm)
Prata	$3,86 \times 10^{-5}$	0,40625
	$7,71 \times 10^{-5}$	0,8125
	$1,54 \times 10^{-4}$	1,625
	$3,09 \times 10^{-4}$	3,25
	$6,17 \times 10^{-4}$	6,5
TiO₂	$7,71 \times 10^{-5}$	1,45
	$1,54 \times 10^{-4}$	2,9
	$3,09 \times 10^{-4}$	5,8
	$6,17 \times 10^{-4}$	11,6
	$1,23 \times 10^{-4}$	23,2

Fonte: Autoria própria.

Em razão da diferença de densidade das nanopartículas de prata e TiO₂, nanofluidos com mesma concentração molar (mol/l) apresentam diferentes concentrações em volume (ppm v/v), entretanto para efeito de análise comparativa da performance dos mesmos é preferível confrontar concentrações molares iguais. Buscando ainda uma melhor performance dos nanofluidos, foi feita uma análise do nanofluido híbrido da prata com o titânio nas mesmas concentrações citadas.

3.4 Preparação dos nanofluidos

Existem diversas técnicas de preparação dos nanofluidos, como exposto em Rocha *et al.* (2019), entre elas pode-se citar a sonificação, redução química, síntese por líquidos iônicos, pirólise a laser, método poliol, microemulsão reversa, síntese hidrotérmica assistida por microondas e rota sonoquímica para síntese de nanofluidos. O preparo do dióxido de titânio foi por dispersão de nanopartículas por meio de sonificação e o de prata foi por redução química de nitrato de prata para formar as nanopartículas dentro do próprio nanofluido.

3.5 Taxa de absorção específica (SAR) e Taxa de energia armazenada (SER)

Visando identificar a capacidade de conversão fototérmica dos nanofluidos foram feitos os levantamentos da taxa de absorção específica (SAR) juntamente com a quantidade de energia

absorvida (SER) pelo nanofluido. A SAR calcula a capacidade de absorção energética das nanopartículas por unidade de massa e pode ser calculada pela Equação 2.

$$SAR = \frac{m_{fb}c_{fb}}{1000m_{np}} \left(\frac{\Delta T_{nf}}{\Delta t} - \frac{\Delta T_{fb}}{\Delta t} \right) \quad (2)$$

Onde m representa a massa, c o calor específico, T a temperatura e t o tempo. Os subscritos fb , np e nf representam o fluido base, nanopartícula e nanofluido, respectivamente.

O presente trabalho também calculou a taxa de energia armazenada, como em Beicker *et al.* (2018), para avaliar a energia absorvida devido à presença das nanopartículas, por meio da Equação 3.

$$SER = \frac{T_{nf}(t) - T_{nf}(0)}{T_{fb}(t) - T_{fb}(0)} \quad (3)$$

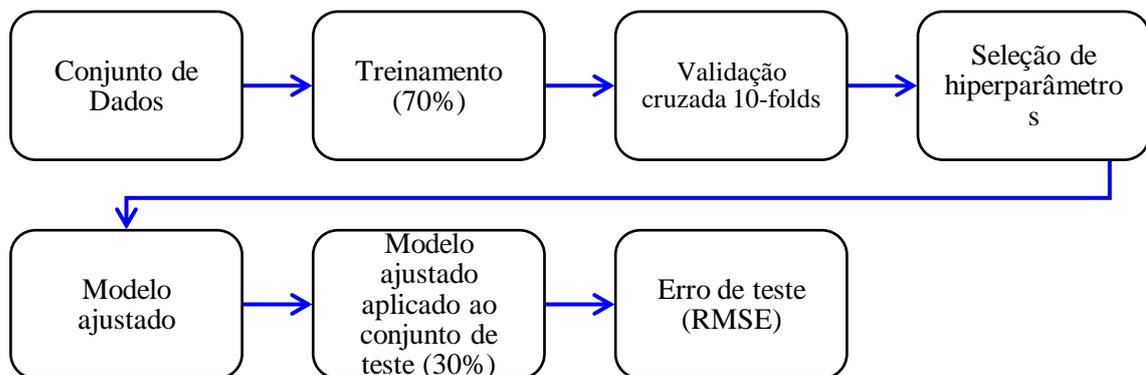
Uma análise conjunta dessas duas métricas possibilita que seja selecionada a concentração ideal de trabalho para o nanofluido.

4 MODELAGEM NUMÉRICA

Os métodos de aprendizado de máquina apresentados no trabalho, cujo objetivo foi prever o comportamento da temperatura do fluido da Parede Solar serão abordados nessa seção. Uma abordagem mais geral e aprofundada dos métodos citados pode ser encontrada em outros trabalhos (JAMES et al., 2013; AHMAD; REYNOLDS; REZGUI, 2018; ALADE; RAHMAN; SALEH, 2019).

Nesse trabalho, dividiu-se o conjunto de dados em duas partes: dados de treinamento e dados de teste, onde 70% dos dados foram usados para treinar o algoritmo e o restante para testar. Com os dados de treinamento usou-se uma validação cruzada 10 – folds, onde todas as observações são divididas em 10 subconjuntos para treinar em 9 deles e validar no subconjunto restante. O processo é repetido 10 vezes até que por fim calculam-se os parâmetros livres para obter o modelo ajustado. A próxima etapa é aplicar o modelo ajustado no conjunto de teste para que se avalie o menor erro de teste. O processo aplicado é descrito na Figura 8. Após utilizar os métodos nos dados de teste, foram calculadas as estatísticas para analisar a acuracidade do modelo, Mean Absolute Error (MAE), R^2 e Root Mean Squared Error (RMSE).

Figura 8 - Separação do conjunto de dados de treino e teste para predição da temperatura do fluido.



Fonte: Autoria própria.

4.1 Regressão de Vetor Suporte (SVR)

A regressão vetorial de suporte é uma das técnicas computacionais com um ramo de aplicação bem extenso, tanto para problemas de classificação como de regressão (AHMAD; REYNOLDS; REZGUI, 2018). O objetivo do SVR é estimar uma função que faça a previsão corretamente dos dados de teste, sem incluir dados de treinamento, onde essa função é dada

através de um hiperplano de separação. Seja (x_i, y_i) o conjunto de dados de treinamento, onde x_i é o preditor e y_i é a resposta, o hiperplano de separação é dado pela Equação 4, onde w é um vetor normal ao plano.

$$f(x) = wx + b \quad (4)$$

A escolha do melhor hiperplano é aquela que seleciona os melhores hiperparâmetros por meio de uma função de custo. O processo de busca por essa função é através da minimização das Equações 5 e 6 (LI et al., 2009).

$$\frac{1}{2} \|w\|^2 + C \frac{1}{N} \sum_1^N L_\varepsilon(Y_i, f(X_i)) \quad (5)$$

$$L_\varepsilon(Y_i, f(X_i)) = \begin{cases} 0, & |Y_i - f(X_i)| < \varepsilon \\ |Y_i - f(X_i)| - \varepsilon, & \text{caso contrário} \end{cases} \quad (6)$$

A norma do vetor w é o termo regularizador que define a margem do hiperplano, C é um parâmetro de penalidade que define a flexibilidade do modelo e o restante da Equação (5) vai definir o erro medido. Nesse caso, o problema de definir o hiperplano ótimo (com uma margem maior) resume-se em resolver o problema de minimizar $\|w\|^2$, onde o processo mais detalhado desse problema de otimização é encontrado em LI *et al.* (2009), obtendo a Equação (7).

$$Y = f(X) = \sum_1^N (\alpha_i - \alpha_i^*) K(X_i, X_j) + b \quad (7)$$

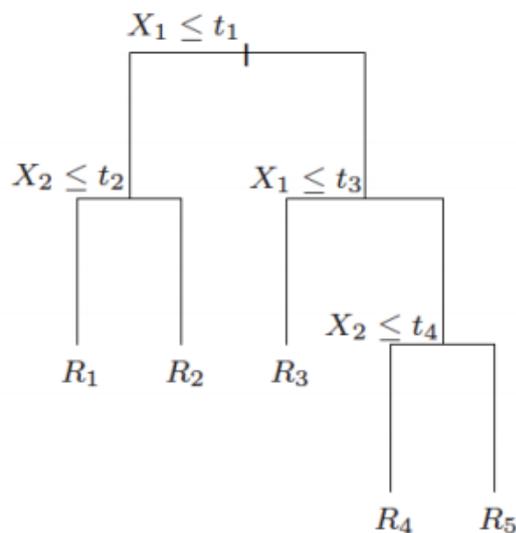
Nessa equação, α_i são os multiplicadores de Lagrange para diversas amostras e $K(X_i, X_j)$ é a função kernel. Algumas vantagens desse método são que ele vai encontrar a melhor solução possível para o problema de otimização em questão, é muito eficiente para problemas de alta dimensão, minimiza o risco de overfitting (ajuste excessivo) e, além de ser um método bastante usado em problemas de classificação, pode ser estendido para problemas de regressão.

4.2 Florestas Aleatórias - Random Forests (RF)

Florestas aleatórias fornecem uma melhoria por meio de um pequeno ajuste que correlaciona as árvores (JAMES et al., 2013). Essas árvores são formadas por meio de diversos testes das variáveis envolvidas e assim a árvore pode ser traduzida da parte superior até a parte inferior, onde na base da árvore tem-se o valor previsto, conforme a Figura 9. A principal vantagem dos métodos baseados em árvores em relação aos demais é a sua capacidade de gerar uma predição rápida sem cálculos computacionais complexos (EL-BAZ; TZSCHEUTSCHLER; WAGNER, 2018). Em contrapartida, os métodos baseados em árvores sofrem de alta variância, de acordo com James et al. (2013). As Florestas Aleatórias geram B amostras *bootstrap* como em Ahmad, Reynolds e Rezgui (2018) e a partir dos seus dados de treinamento, produzem C árvores de decisão. É selecionada aleatoriamente uma quantidade m de preditores para cada árvore gerada nesse novo conjunto de treinamento (m_{try}), selecionando apenas uma pequena quantidade de características (seleção de recurso aleatório), esse processo é repetido e as árvores são cultivadas gerando novas predições. Com os resultados das predições, é feita uma média e assim o modelo final é ajustado. A predição de RF é expressa pela Equação 8, onde $T_i(x)$ são as árvores geradas pelo bootstrap.

$$\hat{f}(x) = \frac{1}{C} \sum_{i=1}^C T_i(x) \quad (8)$$

Figura 9 - Árvore de regressão.



Fonte: JAMES et al., 2013.

4.3 K - Vizinhos mais próximos (KNN)

O método KNN cria fronteiras para definir seus limites de decisão. O algoritmo calcula a norma euclidiana de cada ponto de teste \hat{x} para todos os pontos de treinamento x_i , ou seja, calcula a distância do ponto de teste aos de treinamento, conforme a Equação 9.

$$d_i = \|x_i - \hat{x}\| \quad (9)$$

Para cada ponto de teste, as distâncias são computadas e então a média dos k valores mais próximos da resposta y_i é usada na predição do modelo. Para a predição da temperatura da água foram analisados diversos valores de k e dentre eles se escolheu aquele que obtivesse o menor valor da métrica RMSE, conforme o trabalho de Alfadda, Rahman e Pipattanasomporn (2018).

4.4 Métricas para análise de previsão de temperatura

Quanto à análise estatística, as variáveis data, hora, temperatura e radiação foram agrupadas e analisadas na linguagem R. Com ela, foram realizados os cálculos da estatística R^2 , MAE (erro absoluto médio): magnitude média dos erros de predição, RMSE (raiz do erro médio quadrático): erro médio de predição, que atribui um peso aos erros mais altos.

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{N}} \quad (10)$$

$$MAE = \frac{1}{N} \sum_{i=1}^N |\hat{y}_i - y_i| \quad (11)$$

Para uma melhor análise dos métodos, se fez necessário uma análise dos preditores que mais influenciavam na temperatura da parede solar. A Figura 10 mostra um mapa de correlação entre as variáveis e pode-se perceber que dentre todos os preditores, a data era o preditor que tinha uma baixa correlação com os demais, se mostrando ineficiente para determinar a temperatura da parede Solar. Ao contrário da data tem-se a radiação solar direta e temperatura

ambiente se mostrando como fortes preditores para determinação da temperatura da parede solar. A hora do dia e a radiação solar difusa se mostrou com uma correlação um pouco melhor que a data, mas podendo ser responsável por muitos erros na determinação da temperatura da Parede Solar, já que a correlação não foi tão alta como os demais preditores, isso pode ser causado pelo fato dos experimentos terem alguns dias com céu nublado.

5 RESULTADOS E DISCUSSÕES

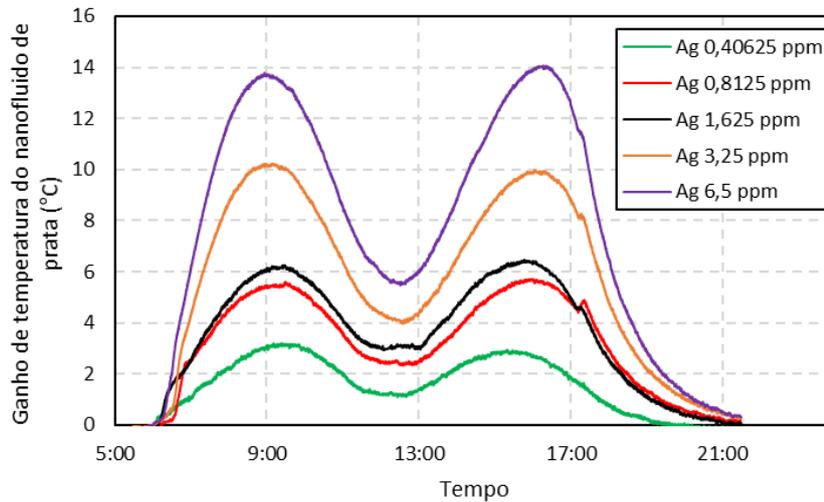
5.1 Resultados experimentais

Essa seção detalha os resultados experimentais, onde foram avaliadas a taxa de absorção específica, ganho de temperatura e taxa de energia armazenada para os nanofluidos de prata, dióxido de titânio e as nanopartículas aglomeradas.

5.1.1 Resultados experimentais para o nanofluido de prata

O desempenho dos nanofluidos de prata foi estudado comparando o aquecimento desses fluidos simultaneamente ao aquecimento de água destilada por exposição à radiação solar. O Gráfico 1 mostra a diferença de temperatura ao longo do experimento, entre os nanofluidos de prata e a água, onde percebe-se que por volta de 12:00 tem-se uma queda considerável e isso se deve ao fato do ângulo de incidência solar na parede vertical. Os gráficos denotam que um aumento na concentração de nanopartículas resulta em um ganho mais expressivo de temperatura. O Gráfico 1, além de mostrar os perfis de temperatura dos nanofluidos, realça que uma concentração de 6,5 ppm representa um ganho de 26%, onde a temperatura de aquecimento conseguiu superar em 14°C a da água. Em contrapartida, a menor concentração, de 0,40625 ppm, resultou em um ganho de 5,2%, correspondendo a uma diferença de 2,8°C.

Gráfico 1 - Ganho de temperatura do nanofluido de prata em relação à água.

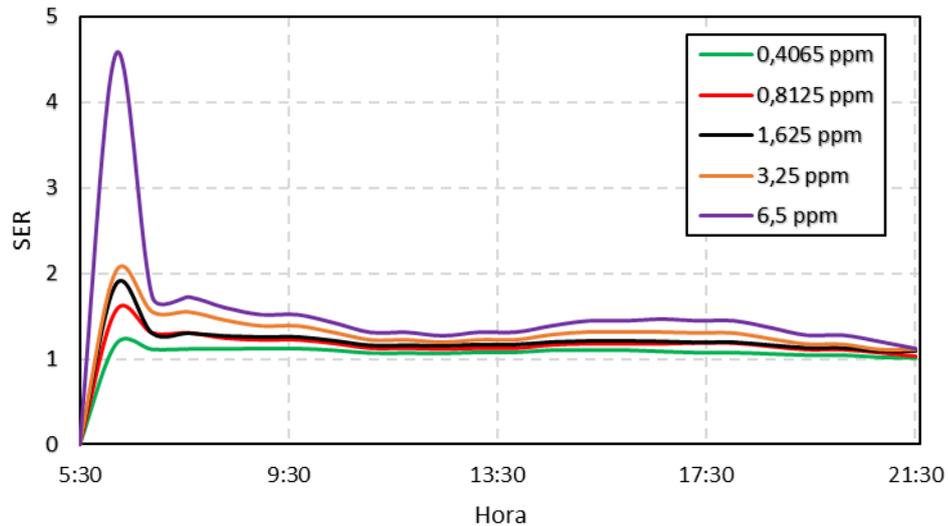


Fonte: Autoria própria.

Esses resultados condizem com os estudos de BAZDIDI-TEHRANI; KHABAZIPUR e VASEFI (2018), MAHBUBUL *et al.* (2018) e COLANGELO *et al.* (2015), que demonstram a influência da concentração das nanopartículas na eficiência de coletores solares.

O Gráfico 2 mostra que concentrações mais altas resultam ganhos mais expressivos de energia nas primeiras horas do dia, logo em seguida essa taxa de energia absorvida reduz significativamente ao longo do dia e depois se mantém praticamente constante. Percebe-se que as partículas de prata são bem eficazes no início da incidência solar, respondendo rapidamente à exposição solar, algo que não acontece com a água destilada, mostrando assim a boa capacidade de absorção energética das partículas de prata, como foi exposto por BANDARRA FILHO *et al.* (2014). O Gráfico 2 também mostra que a prata com 6,5 ppm obtém os melhores resultados no início do dia, seguido pelas menores concentrações, onde por volta de 11:30 a quantidade SER se torna praticamente a mesma para todas as concentrações.

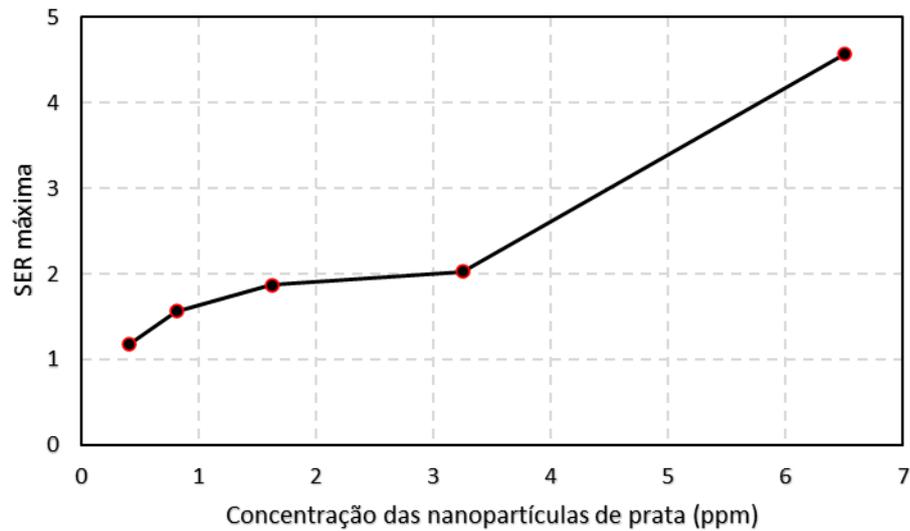
Gráfico 2 - Taxa de energia armazenada dos nanofluidos para diversas concentrações.



Fonte: Autoria própria.

O Gráfico 2 mostra a variação de energia armazenada em função do tempo para as concentrações estudadas. É perceptível que o aumento das concentrações implica em uma maior energia absorvida pelo fluido, de modo que ocorre uma decalagem das curvas em função desse aumento. Beicker *et al.* (2018) e Bandarra Filho *et al.* (2014) mostraram que em maiores concentrações a SER pode se estabilizar, mostrando assim que nem sempre o aumento da concentração vai ser satisfatório, pois o ganho será irrelevante em função de custos e trabalho com preparações desses nanofluidos. Nesse estudo, a prata alcançou um SER máximo de 4,57, onde estudos com concentrações mais elevadas são necessários para que se chegue na estabilidade de SER, conforme o Gráfico 3.

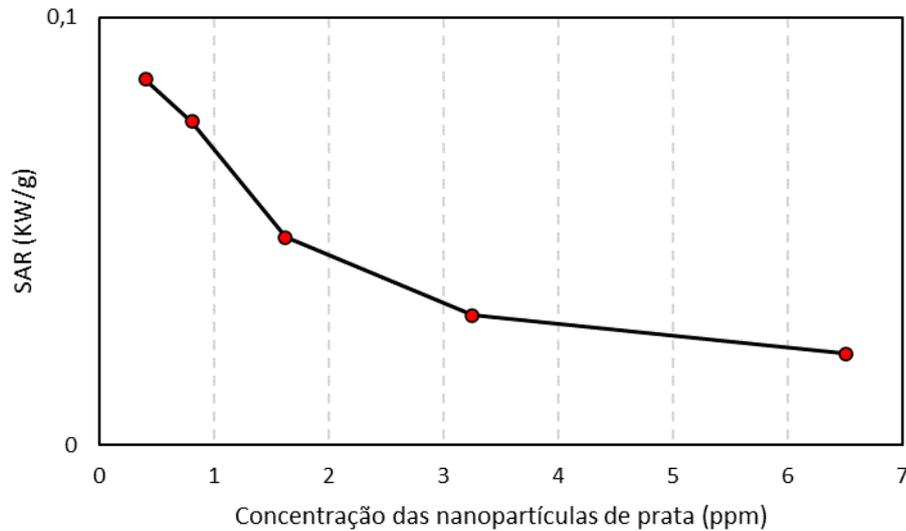
Gráfico 3 - Máxima taxa de energia absorvida em função da concentração.



Fonte: Autoria própria.

Outro cálculo relevante para avaliar a capacidade de absorção do nanofluido de prata é a capacidade de absorção energética das nanopartículas por unidade de massa (SAR). O Gráfico 4 mostra como a SAR varia em função da concentração, obtendo um comportamento inversamente proporcional ao SER, implicando em uma redução na capacidade fototérmica por nanopartícula. Beicker *et al.* (2018) mostraram que o comportamento da SAR vai se estabilizar em concentrações mais elevadas, validando o comportamento de energia armazenada que também se estabiliza em altas concentrações. Após a estabilidade da SER e SAR é escolhida a concentração ideal de trabalho.

Gráfico 4 - Taxa de absorção específica por unidade de massa em função da concentração de nanopartículas de prata.

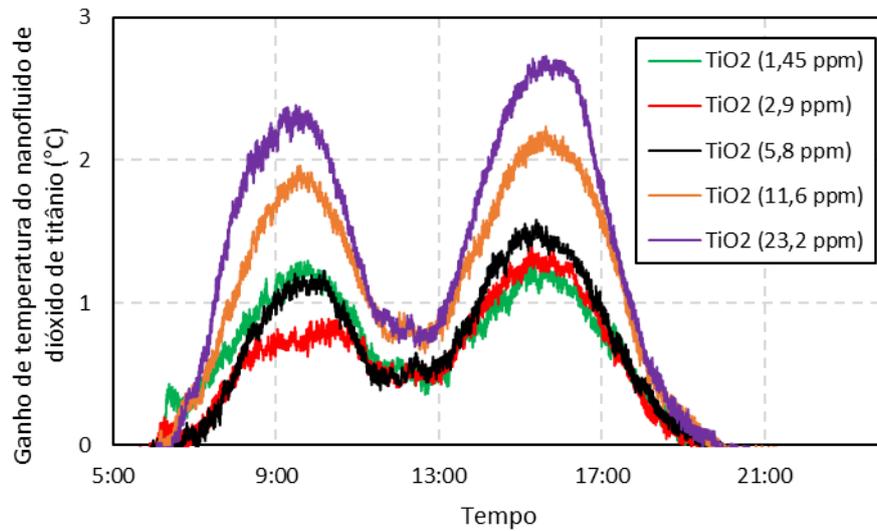


Fonte: Autoria própria.

5.1.2 Resultados experimentais para o nanofluido de dióxido de titânio (TiO_2)

O estudo dos nanofluidos de dióxido de titânio (TiO_2) foi realizado de maneira análoga aos experimentos feitos com os nanofluidos de prata. O Gráfico 5 mostra que os nanofluidos de dióxido de titânio registram temperaturas ligeiramente superiores à temperatura da água destilada nos experimentos realizados. O comportamento das curvas de temperatura foi bem similar às curvas de nanofluido de prata, mostrando uma correlação positiva entre a concentração e o ganho de temperatura. Algumas variações podem ser notadas no início do dia, em função provavelmente das condições meteorológicas, como ocorrido para a concentração de 2,9 ppm, entretanto, na segunda metade do dia, os gráficos confirmam a tendência de quanto maior a concentração, maior a temperatura. A menor concentração de 1,45 ppm mostra um ganho de temperatura de $1,3^{\circ}C$, sendo 2,4% superior à água destilada. Já a maior concentração de 23,2 ppm resulta em uma diferença de temperatura de $2,7^{\circ}C$, que corresponde ao ganho de 5,0%. O TiO_2 apresentou ganhos inferiores à prata, e um fator relevante para tal acontecimento pode ser a coloração do nanofluido de dióxido de titânio, que apresentou tonalidade branca, podendo ter refletido parte da radiação solar, mostrando desempenho inferior com relação à prata.

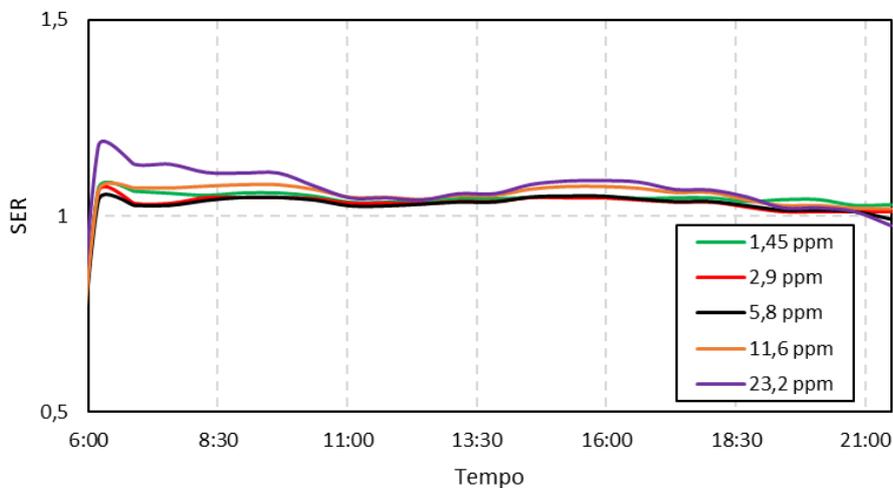
Gráfico 5 - Ganho de temperatura do nanofluido de dióxido de titânio (TiO₂) em relação à água.



Fonte: Autoria própria.

O gráfico 6 fornece as informações do aumento diferencial de energia atingido com a adição de nanopartículas ao fluido base. Observa-se, mais uma vez, uma similaridade no comportamento da curva do SER, como o ocorrido para a prata. Verifica-se uma maior taxa de energia armazenada no início do dia, que vai diminuindo ao longo do tempo. Observa-se também um deslocamento da curva SER em função do aumento da concentração do nanofluido. Entretanto, depois de um certo tempo o efeito da concentração se reduz, mostrando uma tendência de estabilização dessa quantidade.

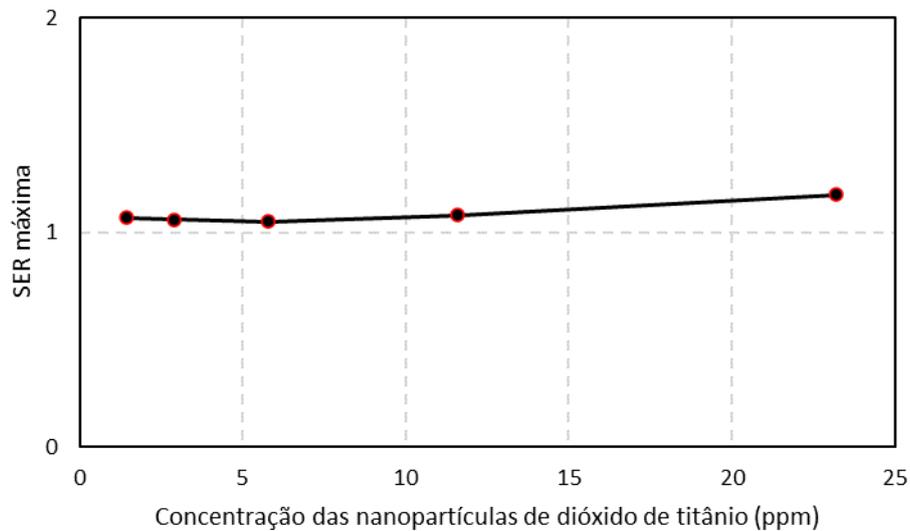
Gráfico 6 - Taxa de energia armazenada pelas nanopartículas de dióxido de titânio.



Fonte: Autoria própria.

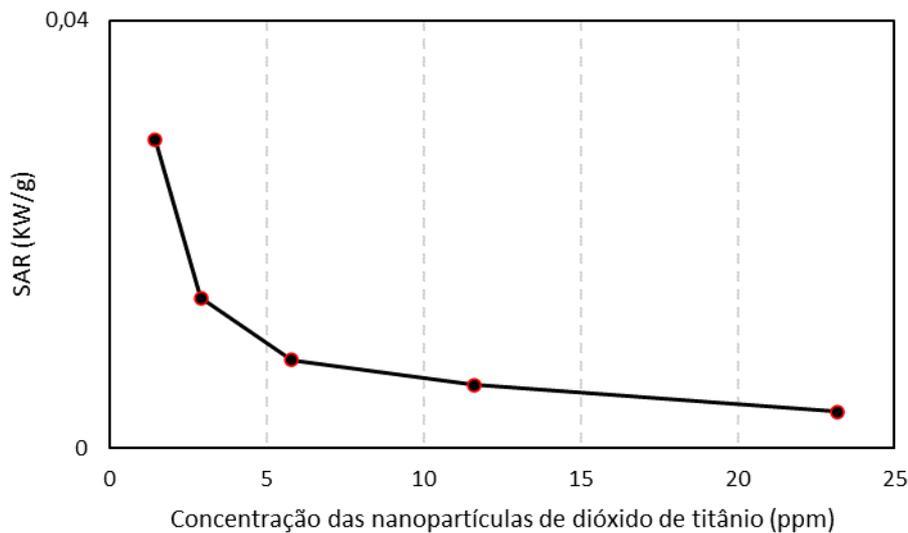
O Gráfico 7 também relaciona a SER com a concentração, onde uma maior concentração resulta em uma energia extra absorvida devido à incidência solar. Esse resultado mostra que as nanopartículas de TiO_2 não aumentam a SER de maneira significativa, ficando muito próximo de 1 para todas as concentrações estudadas, de tal forma que a SER para todas as concentrações é praticamente a mesma, reafirmando assim que essa taxa de energia armazenada tende a se estabilizar.

Gráfico 7 - SER máxima em função da concentração.



Fonte: Autoria própria.

O Gráfico 8 relaciona a quantidade SAR com a concentração, evidenciando, mais uma vez, um comportamento similar ao anotado para as nanopartículas de prata. Entretanto, para o dióxido de titânio essas quantidades mostram-se com uma pequena variação de 0,04 KW/g, já mostrando uma tendência para estabilizar a SAR a uma concentração de 5,8 ppm, mostrando assim que um aumento na concentração após 5,8 ppm não causa qualquer efeito significativo na SAR.

Gráfico 8 - Variação de SAR em função da concentração (TiO₂).

Fonte: Autoria própria.

5.1.3 Análise de SER e SAR para os nanofluidos de prata e dióxido de titânio

Os resultados mostraram que a taxa de energia armazenada devido à presença das nanopartículas aumenta de acordo com o aumento da concentração das nanopartículas. Essa correlação aconteceu para os nanofluidos de prata e de forma mais discreta para os nanofluidos de TiO₂. Era esperado que a um certo nível de concentração de nanopartículas o valor de SER atingisse um patamar estável a partir do qual não houvesse mais aumento dessa quantidade. Para os nanofluidos de prata não se observou um valor constante da quantidade SER dentro das concentrações estudadas. Isso indica que um aumento de concentração acima de 6,5 ppm ainda poderia melhorar a performance desse nanofluido. Entretanto, soluções mais concentradas propiciam dificuldades de estabilização dos nanofluidos ocasionando aglomerações de partículas e precipitações.

Diferentemente do nanofluido de prata, os nanofluidos de TiO₂ mostram uma pequena variação da SER em função do aumento da concentração. De certa forma, essa estabilidade foi atingida na concentração de 1,45 ppm, embora que, com valores de SER relativamente baixos não houve necessidade de preparo de soluções mais concentradas, uma vez que o experimento mostrou que um aumento de concentração não contribuiria para melhorar a performance do nanofluido.

A concentração ideal de um nanofluido como fluido de trabalho pode ser indicada pela análise simultânea dos valores SER e SAR. Para as nanopartículas de prata também não houve uma estabilização de SAR, já para TiO₂ a quantidade de energia absorvida por unidade de massa

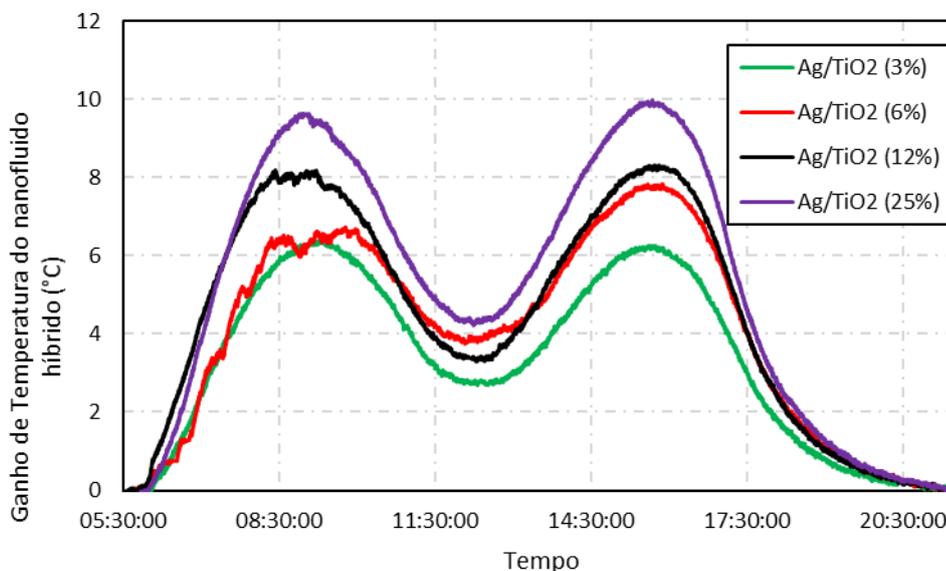
apresentou uma pequena variação, obtendo uma estabilidade em 5,8 ppm, podendo-se inferir que uma concentração de 1,45 ppm seria o ideal para as nanopartículas de dióxido de titânio quando se analisa SER e SAR simultaneamente.

5.1.4 Resultados experimentais para o nanofluido híbrido

A análise do nanofluido híbrido (prata – dióxido de titânio) foi feita fixando a concentração de TiO_2 em 23,2 ppm e dopando com diversas concentrações de prata (0,40625 ppm – 0,8125 ppm – 1,625 ppm e 3,25 ppm), correspondendo a fração molar de aproximadamente 3%, 6%, 12% e 25% respectivamente, similar à pesquisa de YU e XUAN (2018) que usaram o nanofluido de prata disperso na superfície do óxido de cobre. A concentração do dióxido de titânio se manteve constante pois os experimentos com os nanofluidos isolados mostraram a superioridade da prata com relação ao TiO_2 , e assim buscou-se melhorar gradativamente o TiO_2 fazendo a dopagem com prata.

O Gráfico 9 mostra o resultado da diferença de temperatura entre o nanofluido híbrido e a água, onde percebe-se que quanto maior a fração molar de prata inserida no dióxido de titânio, maior é o ganho de temperatura. Resultados similares mostraram que uma maior fração em volume implicava em uma maior condutividade térmica dos nanofluidos (RANGA BABU *et al.*, 2017). A fração molar de 3% (0,40625 ppm de prata – 23,2 ppm de TiO_2) conseguiu um ganho de 6,4°C em comparação com a água, onde esse ganho representa uma melhoria de 11,6%, já uma fração molar de 25% (3,25 ppm de prata – 23,2 ppm de TiO_2) conseguiu um ganho de 9,9°C, sendo representado por uma melhoria de 18,3%.

Gráfico 9 - Variação de temperatura do fluido híbrido.



Fonte: Autoria própria.

A Tabela 2 mostra o comparativo entre as concentrações dos nanofluidos isolados e do híbrido. Quando se aumenta a fração molar de prata no dióxido de titânio, o ganho de temperatura sempre melhora, partindo de 11,6% até 18,3%, o mesmo acontecendo com os nanofluidos isolados. Outro fator relevante que se pode destacar da Tabela 1 é que o nanofluido híbrido sempre se torna melhor que a prata isolada, com exceção da fração molar de 25%, onde a prata supera o nanofluido híbrido, tornando desnecessário o preparo do mesmo quando se deseja um ganho de temperatura, e assim a fração molar de 12% se torna ideal para essa situação, onde pode-se destacar que a fração molar de 12% obteve um ganho de 8,3°C. De acordo com o apresentado, pode-se verificar que os nanofluidos de prata e TiO₂ obtiveram resultados superiores aos da água. Em função disso combinou-se as duas melhorias alcançando resultados mais eficientes com a mistura dos nanofluidos. Outro resultado importante que se pode extrair da tabela 1 é o fato da fração molar de 3% obter um ganho superior ao da soma algébrica dos nanofluidos separadamente, onde o ganho da soma algébrica é de 5,5°C e o do nanofluido híbrido é de 6,4°C.

Tabela 2 - Comparativo entre nanofluidos híbridos e isolados.

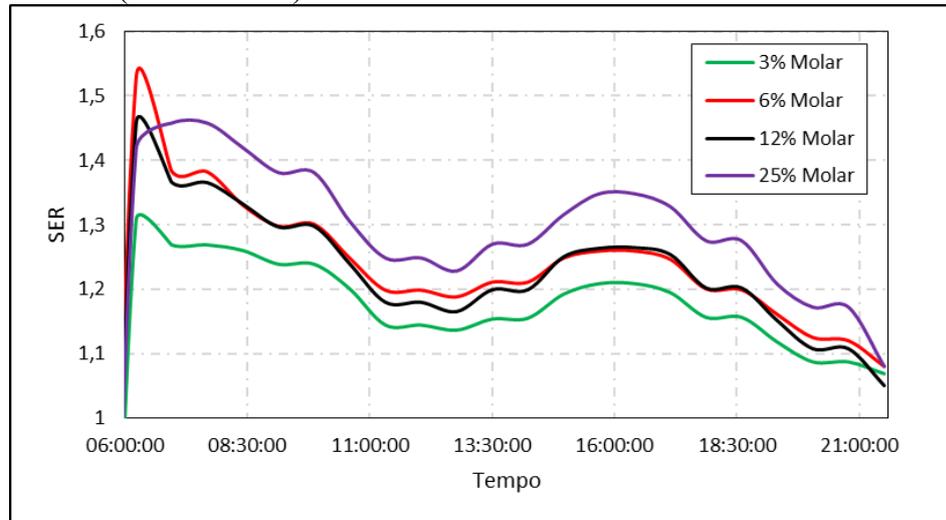
Nanofluidos (Comparativos)	Ganho de Temperatura (°C) e ganho percentual
Prata (0,40625 ppm)	2,8 - (5,2%)
TiO ₂ (23,2 ppm)	2,7 - (5%)
Híbrido (Fração Molar 3%)	6,4 - (11,6%)
Prata (0,8125 ppm)	5,7 - (10,6%)
TiO ₂ (23,2 ppm)	2,7 - (5%)
Híbrido (Fração Molar 6%)	7,8 - (14,3%)
Prata (1,625 ppm)	6,5 - (11,7%)
TiO ₂ (23,2 ppm)	2,7 - (5%)
Híbrido (Fração Molar 12%)	8,3 - (14,9%)
Prata (3,25 ppm)	10,2 - (19,3%)
TiO ₂ (23,2 ppm)	2,7 - (5%)
Híbrido (Fração Molar 25%)	9,9 - (18,3%)

Fonte: Autoria própria.

5.1.5 *Análise de SER para o nanofluido híbrido*

O Gráfico 10 mostra como varia a SER em função do tempo, onde o resultado deixa clara a grande capacidade do nanofluido em absorver energia nas primeiras horas do dia, mas logo em seguida essa capacidade cai para todas as amostras, como já tinha sido observado com os nanofluidos isolados. Os pontos mais altos de SER são observados no início do dia, pois é nesse momento que há uma maior variação de temperatura do nanofluido em relação à água. Outro resultado observado é que a fração molar de 6% obteve os melhores índices de energia absorvida, e para a SER mostrou-se superior aos demais experimentos. A SER não seguiu a mesma tendência dos nanofluidos isolados, onde a segunda maior fração molar obteve os ganhos mais relevantes.

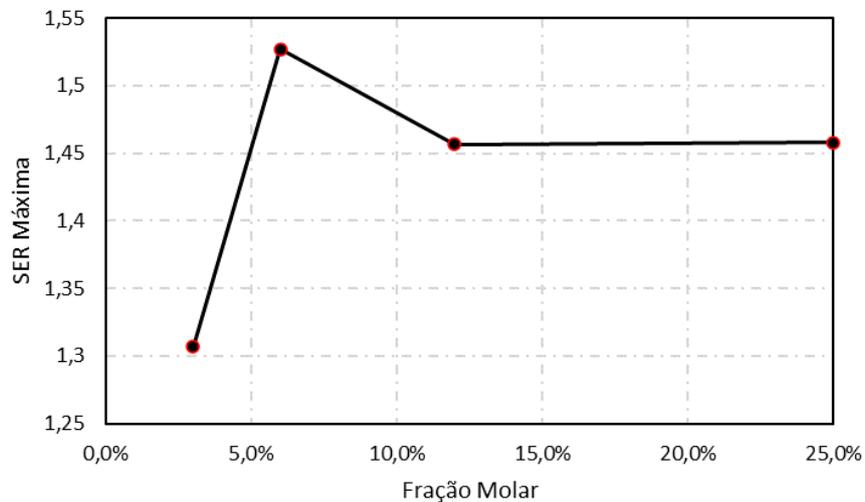
Gráfico 10 - Taxa de energia armazenada para o nanofluido híbrido (Prata – TiO₂).



Fonte: Autoria própria.

O Gráfico 11 mostra como variou essa razão de energia armazenada em função da fração molar do nanofluido. Esse resultado mostra que nem sempre acrescentar uma quantidade a mais de prata implica em uma maior energia armazenada, sendo desnecessária uma fração de molar de 12% e 25% para o nanofluido híbrido quando se deseja uma maior SER. Outro fato relevante que se pode observar no Gráfico 10, é que esse comportamento não segue a mesma tendência dos nanofluidos de prata e dióxido de titânio isoladamente, onde o valor de SER aumentava de acordo com o aumento das concentrações, e para o nanofluido com fração molar de 6% o maior ganho de energia armazenada já foi observado.

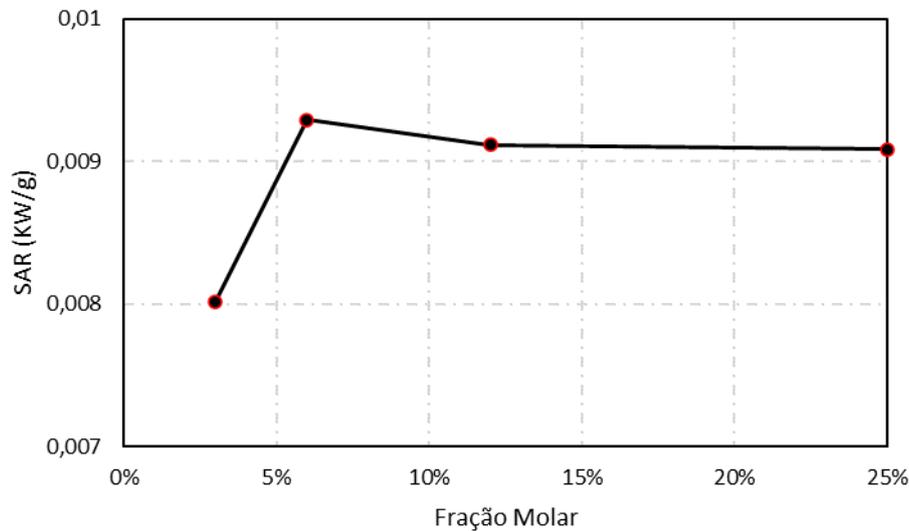
Gráfico 11 - Razão de energia absorvida em função da concentração de prata no dióxido de titânio.



Fonte: Autoria própria.

A taxa de absorção específica (SAR) também foi calculada para o nanofluido híbrido, onde o Gráfico 12 mostra como esta varia em função da fração molar do nanofluido híbrido. Percebe-se que a quantidade SAR aumenta para a amostra de 6% e logo em seguida reduz, tendendo a uma estabilidade por volta de 0,009 KW/g. Os resultados de Beicker *et al.* (2018) e Bandarra Filho *et al.* (2014) mostraram que a SAR diminui com a concentração até o momento de se estabilizar, mas esses resultados foram encontrados em amostras de nanofluidos isolados. O nanofluido híbrido de prata com dióxido de titânio obteve um aumento na SAR e logo em seguida uma redução, isso pode ser devido ao fato das interações de partículas diferentes. A fração molar de 6% mais uma vez apresentou melhores resultados.

Gráfico 12 - Variação de SAR em função da fração molar do nanofluido híbrido.



Fonte: Autoria própria.

5.2 Análise numérica

Esse tópico apresenta os resultados dos modelos de aprendizagem de máquina, onde cada método procurou prever a temperatura da Parede Solar, através de variáveis de entrada como a temperatura ambiente, radiação solar direta, difusa e global, temperatura de radiação (sensação térmica), data e hora de tal forma que o menor índice de erro fosse alcançado.

5.2.1 Resultados do SVR

Diferentes fatores afetam os resultados do SVR para a previsão dos dados; o parâmetro da penalidade C juntamente com o termo ε precisam ser ajustados na fase de treinamento. A fase de treino vai ajustar o modelo aos dados de tal forma que consiga obter o menor erro possível na fase de teste. A escolha do kernel de base radial (RBF) é baseada em suas amostras de mapeamento não linear em um espaço de grande dimensão e porque pode lidar facilmente com a relação não linear entre rótulos e atributos de classe (DONG, CAO, LEE, 2005). Durante a fase de treinamento, o algoritmo selecionou um parâmetro ideal (por exemplo, $\varepsilon = 0,1$). Na próxima etapa, o método definiu o parâmetro escolhido e variou o valor de C para encontrar aquele com o menor RMSE. A Tabela 3 mostra os resultados da escolha dos melhores hiperparâmetros, onde um valor de $C = 32$ foi obtido para todos os fluidos.

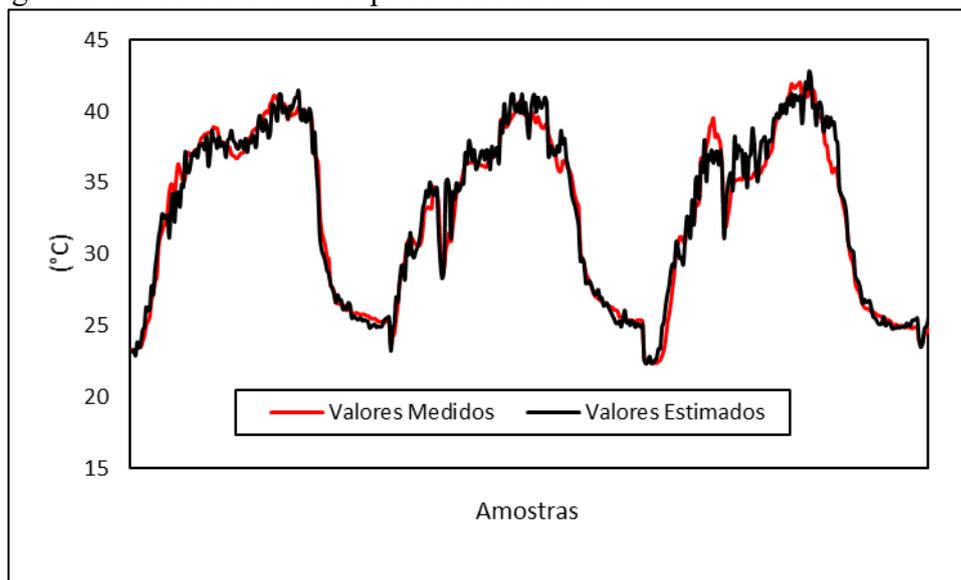
O Gráfico 13 mostra a comparação entre os valores calculados pelo modelo e os valores medidos. O método SVR se comportou de maneira bastante satisfatória. Pode-se observar que as previsões podem acompanhar grande parte dos dados durante o teste, mostrando ótima previsibilidade.

Tabela 3 - Resultados de SVR – Seleção dos hiperparâmetros em função das métricas de erro.

C	Água		
	$RMSE(^{\circ}C)$	R^2	$MAE(^{\circ}C)$
0,25	0,996	0,976	0,701
0,50	0,943	0,979	0,659
1,0	0,900	0,980	0,626
2,0	0,871	0,982	0,606
4,0	0,852	0,982	0,591
8,0	0,837	0,983	0,578
16	0,826	0,983	0,567
32	0,816	0,984	0,550
64	0,819	0,984	0,558
128	0,816	0,984	0,552

Fonte: Autoria própria.

Gráfico 13 - Comparação entre os valores medidos experimentalmente para a água e os valores calculados pelo método SVR.



Fonte: Autoria Própria.

5.2.2 Resultados do RF

O método de Florestas Aleatórias leva em consideração alguns hiperparâmetros, como o número de árvores e preditores, para obter o resultado mais conveniente. Um número bem definido de árvores deve ser determinado para encontrar uma troca entre poder preditivo e tempo computacional (AHMAD, REYNOLDS, REZGUI, 2018). Além disso, é preciso selecionar uma divisão contributiva entre um subconjunto de variáveis de entrada m_{try} (AHMAD, REYNOLDS, REZGUI, 2018).

Para este trabalho, foram especificadas 200 árvores durante a fase de treinamento, que busca os hiperparâmetros. Uma vez fixado o número de árvores, o algoritmo variou o número de atributos m_{try} e buscou o menor valor de RMSE. O melhor modelo foi alcançado quando o RF utilizou 6 variáveis de entrada para o fluido nas três condições, conforme Tabela 4. O único preditor não selecionado no modelo foi a data que contém o dia e o mês, sendo as demais variáveis extremamente importantes: Temperatura do ar, radiação solar direta, radiação solar global, radiação solar difusa, temperatura de radiação solar (sensação térmica) e tempo.

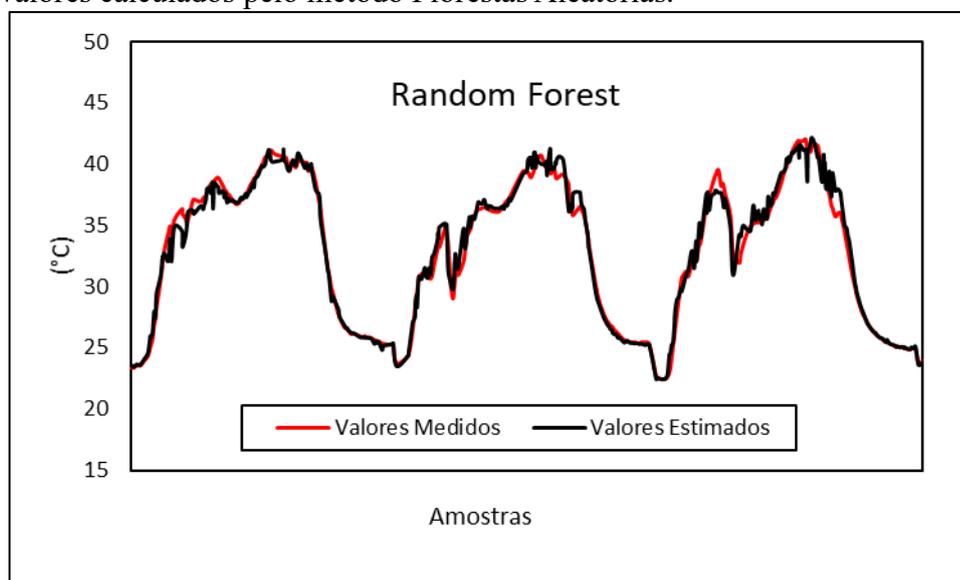
Tabela 4 - Resultados de Florestas Aleatórias – Seleção dos hiperparâmetros de acordo com as métricas de erro.

m_{try}	Água		
	RMSE(°C)	$R_{quadrado}$	MAE(°C)
2	0,698	0,988	0,437
3	0,664	0,989	0,404
4	0,645	0,990	0,385
5	0,636	0,990	0,374
6	0,634	0,990	0,368
7	0,637	0,990	0,369

Fonte: Autoria própria.

O Gráfico 14 mostra como esse método se comporta de forma satisfatória, onde percebe-se uma ótima sobreposição das curvas na comparação dos valores estimados e valores medidos.

Gráfico 14 - Comparação entre os valores medidos experimentalmente e os valores calculados pelo método Florestas Aleatórias.



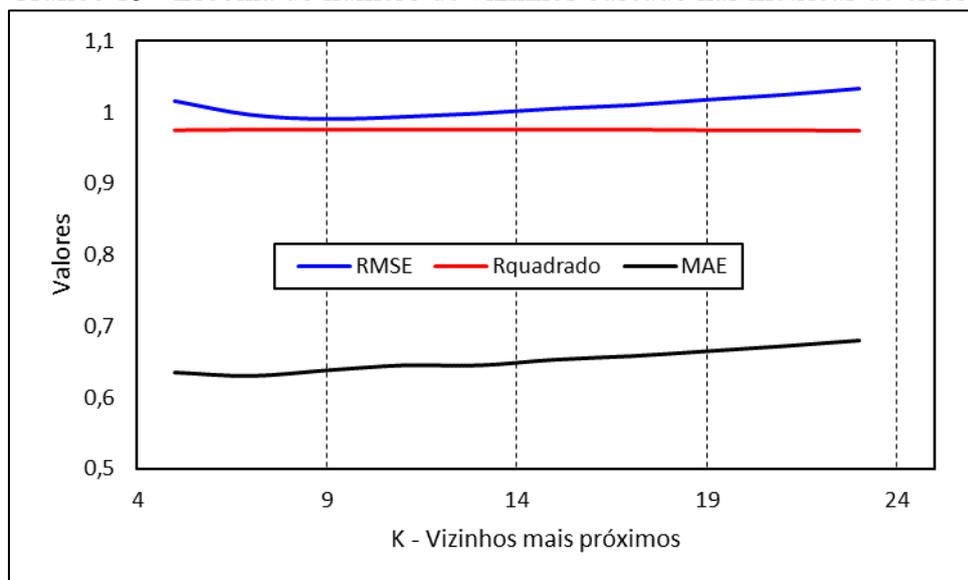
Fonte: Autoria Própria.

5.2.3 Resultados do KNN

O número de vizinhos mais próximos (k), um parâmetro livre, foi analisado no modelo KNN. O modelo foi otimizado alterando o número de vizinhos próximos e calculando os respectivos valores RMSE. Na busca pelo melhor hiperparâmetro, o modelo obteve um valor de $k = 5$ para os diversos fluidos testados. O Gráfico 15 mostra um aumento progressivo nas

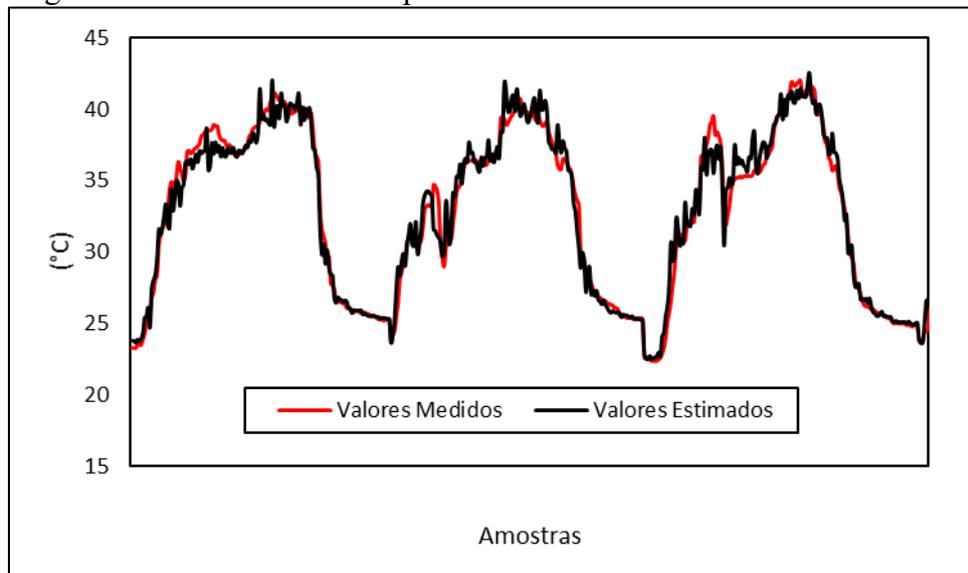
métricas de erro, RMSE e MAE, em função do aumento no valor k. Consequentemente, o melhor valor para as métricas de erro foi calculado considerando a quantidade de vizinhos igual a 5, resultando em $RMSE = 0,918 \text{ } ^\circ\text{C}$ e $MAE = 0,571 \text{ } ^\circ\text{C}$. Definindo a escolha do número de vizinhos, o modelo prevê os dados desconhecidos e os compara com os valores experimentais. O Gráfico 16 mostra os valores medidos e resultados estimados pelo KNN. O método se mostrou muito irregular na maioria das observações, apresentando oscilações a qualquer momento, obtendo assim uma previsão não confiável para o valor da temperatura do fluido.

Gráfico 15 - Escolha do número de vizinhos baseado nas métricas de erros.



Fonte: Autoria própria.

Gráfico 16 - Comparação entre os valores medidos experimentalmente para a água e os valores calculados pelo método KNN.



Fonte: Autoria própria.

5.2.4 Resultados do conjunto de teste

Após o treinamento dos métodos, os algoritmos foram aplicados aos conjuntos de teste, gerando o erro de teste (RMSE). A Tabela 4 mostra os resultados de treinamento e teste para a água. A comparação entre todos os resultados indica que o RF e o SVM produzem valores relativamente baixos de RMSE. O método das Florestas Aleatórias foi superior ao SVR obtendo um RMSE de 0,562°C na fase de teste contra um RMSE de 0,818°C do SVR, obtendo um RMSE 31,29% menor. Analisando a outra métrica de erro, MAE, RF obteve uma taxa de erro menor que SVR, sendo de 0,340°C contra 0,532°C, resultando em um MAE 36,09% menor. Com relação ao KNN, RF obteve um RMSE e MAE melhor em 34,42% e 35,11% respectivamente. Por fim, a métrica R^2 obteve um ótimo comportamento para os três métodos. Esses resultados são semelhantes aos obtidos por Ahmad, Reynolds e Rezgui (2018), em que Florestas Aleatórias foi o melhor método para prever energia solar útil por hora. RF conseguiu valores satisfatórios de taxas de erros para medição da temperatura da Parede Solar. SVR obteve valores de erros levemente maiores que o RF, mas analisando esse erro do SVR, considera-se algo aceitável, pois o mesmo ainda tem uma acuracidade boa quando se compara com os dados coletados. O KNN obteve algumas irregularidades nas previsões e taxas de erros superiores aos demais métodos.

Tabela 5 - Resultados dos conjuntos de teste e treinamento (água).

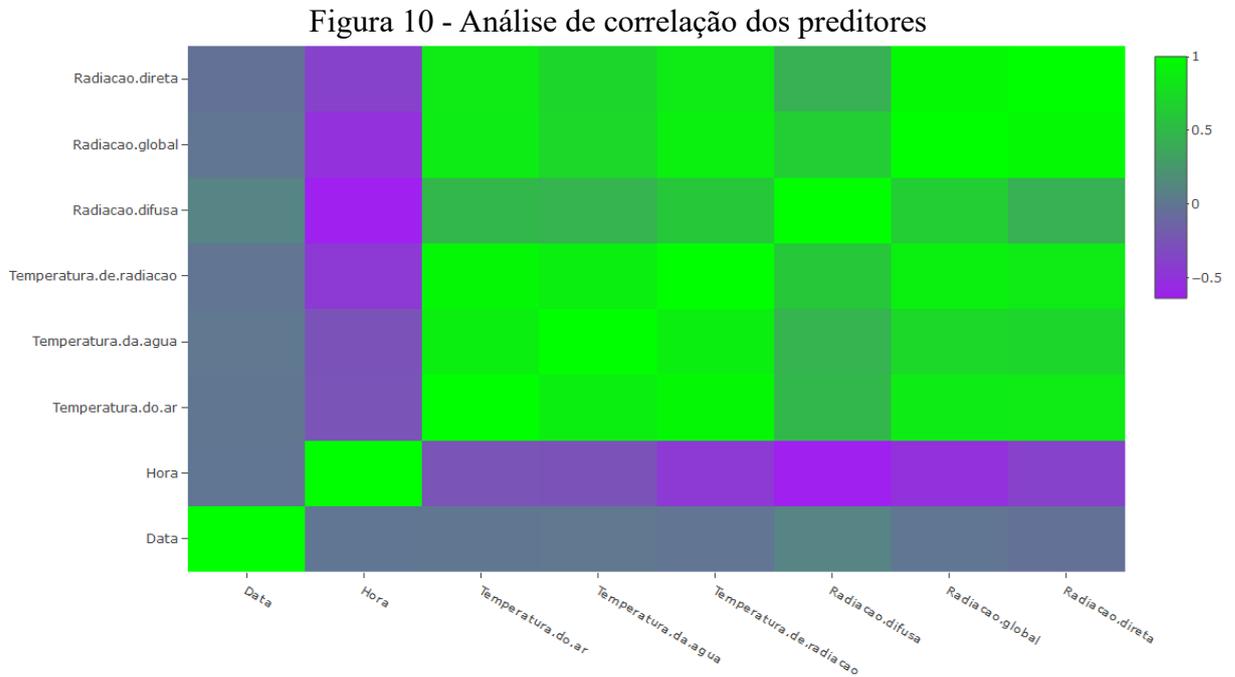
Métodos	Dados de treinamento			Dados de teste		
	RMSE(°C)	MAE(°C)	R^2	RMSE(°C)	MAE(°C)	R^2
SVR	0,680	0,488	0,988	0,818	0,532	0,983
RF	0,260	1,148	0,998	0,562	0,340	0,992
KNN	0,726	0,447	0,987	0,857	0,524	0,928

Fonte: Autoria própria.

5.2.5 Análise dos preditores

Para uma melhor análise dos métodos, se fez necessário uma análise dos preditores que mais influenciavam na temperatura da parede solar. A Figura 10 mostra um mapa de correlação entre as variáveis e pode-se perceber que dentre todos os preditores, a data era o preditor que tinha uma baixa correlação com os demais, se mostrando ineficiente para determinar a temperatura da parede Solar. Ao contrário da data tem-se a radiação solar direta e temperatura ambiente se mostrando como fortes preditores para determinação da temperatura da parede solar.

A hora do dia e a radiação solar difusa se mostrou com uma correlação um pouco melhor que a data, mas podendo ser responsável por muitos erros na determinação da temperatura da Parede Solar, já que a correlação não foi tão alta como os demais preditores, isso pode ser causado pelo fato dos experimentos terem alguns dias com céu nublado.



Fonte: Autoria própria.

6 CONCLUSÃO

A partir dos experimentos realizados, percebeu-se uma diferença significativa entre os nanofluidos de prata e dióxido de titânio, onde o ganho de temperatura da prata foi de 26% em comparação com 5% de TiO_2 , mostrando assim a superioridade da prata em comparação com TiO_2 . O aumento na concentração das nanopartículas também foi um fator influenciador no ganho de temperatura, onde maiores concentrações resultaram em maiores temperaturas. Também foi notado que ambos nanofluidos se comportaram com perfis de temperaturas similares ao longo do dia, e desse fato pode-se inferir que o aumento das concentrações pode ter uma maior relação com a capacidade do fluido de transmitir energia do que as propriedades térmicas das nanopartículas.

O aumento nas concentrações também implicou em uma maior energia armazenada durante o aquecimento, e a prata mais uma vez obteve uma melhor performance que o TiO_2 . As concentrações estudadas para as nanopartículas de prata mostraram uma tendência crescente de ganho de energia, sendo necessário o estudo de maiores concentrações para que se busque a estabilidade de SER e consiga uma concentração ideal de trabalho. As concentrações de TiO_2 já mostraram a melhor performance das nanopartículas, já que um aumento nas concentrações não implicou em ganhos relevantes.

A SAR apresentou uma tendência de redução com o aumento da concentração, onde manteve-se constante para o TiO_2 a partir de 5,8 ppm, mas para a prata ainda se faz necessário um estudo de maiores concentrações para combinar com a SER e determinar uma concentração ideal de trabalho.

Por fim pode-se concluir uma melhor performance das nanopartículas de prata em relação ao TiO_2 , onde se faz necessária uma avaliação de viabilidade econômica para preparo das nanopartículas e o tipo de aplicação para que se selecione o nanofluido ideal. Um fator que pode estar relacionado com os melhores resultados da prata é a coloração do nanofluido, já que TiO_2 apresentou uma coloração branca e pode ter refletido parte da radiação.

Os resultados indicam que a estabilidade de SER e SAR determina a concentração ideal de trabalho, onde para a prata se faz necessária análise de concentrações mais elevadas e para o TiO_2 chegou-se em uma concentração ideal de 1,45 ppm, não se fazendo necessária uma maior concentração, pois se tornaria inviável quando se relacionam benefícios e custos de produção.

Com relação ao ganho de temperatura dos nanofluidos híbridos, foram analisadas 4 frações molares (3%, 6%, 12% e 25%), onde a fração molar de 25% apresentou um maior ganho de temperatura, sendo representado por 18,3% de ganho, mas a prata isoladamente nas mesmas

concentrações apresentou um ganho de 19,3%, mostrando assim a inviabilidade do nanofluido híbrido para essa concentração molar. Em contrapartida, as frações molares de 6% e 12% conseguiram resultados superiores aos da prata, obtendo ganhos de 14,3% e 14,9%. Nessas condições de perfil de temperatura, o nanofluido híbrido apresentou os melhores resultados com uma fração molar de 6% (0,8125 ppm de prata e 23,2 ppm de dióxido de titânio) e de 12% (1,625 ppm de prata e 23,2 ppm de dióxido de titânio).

Na análise de SER observou-se uma maior razão de energia absorvida para a fração molar de 6%, onde o nanofluido apresentou boa resposta nas primeiras horas de experimento.

A análise da taxa de absorção específica comprovou mais uma vez o bom comportamento do nanofluido híbrido com fração molar de 6%, onde essa amostra mostrou uma melhor resposta para o SAR, apresentando uma máxima de 9,293 W/g.

A escolha da melhor concentração de prata no nanofluido híbrido foi de 0,8125 ppm em uma concentração de 23,2 ppm de TiO_2 , onde outras concentrações não apresentaram ganhos superiores.

Esse estudo mostrou como buscar melhorias em nanofluidos, onde uma junção entre duas nanopartículas ainda sim pode alcançar resultados mais expressivos.

O trabalho apresentou o uso de métodos de aprendizado de máquina para prever a temperatura do fluido em um coletor solar, a fim de obter sua capacidade de absorção de energia. Os resultados mostraram que a modelagem numérica pode auxiliar no estudo de fluidos e nanofluidos.

Os valores mais baixos de RMSE para o conjunto de testes foram obtidos usando os métodos das Florestas Aleatórias e SVR. Valores de 0,562° C e 0,818° C foram encontrados para o RMSE, respectivamente, para Florestas Aleatórias e SVR, revelando os métodos como os mais assertivos nas previsões das três análises. Erros de teste ligeiramente mais altos, de 0,857°C, foram encontrados para o KNN.

Uma seleção de atributos de entrada para análise de dados foi realizada pelo método das Florestas Aleatórias. Entre os 7 atributos, o algoritmo selecionou o melhor modelo contendo apenas 6 preditores. A "data" foi a variável de entrada excluída do melhor modelo. O preditor excluído não influenciou nos resultados da predição, o que mostra a alta precisão das Florestas Aleatórias em relação aos demais. No entanto, outros preditores como temperatura ambiente, temperatura da radiação solar, tempo, radiação solar direta, radiação solar difusa e radiação global parecem ser essenciais para o modelo obter uma boa previsão.

Os métodos de aprendizado de máquina foram adequados para o objetivo do estudo e podem ser estendidos a aplicações de estimativa rápida e precisa da previsão de temperatura do fluido em sistemas solares térmicos.

REFERÊNCIAS

AHMAD, M. W; REYNOLDS, J; REZGUI, Y. Predictive modelling for solar thermal energy systems: A comparison of support vector regression, random forest, extra trees and regression trees. **Journal of Cleaner Production**, v. 203, p. 810-821, 2018.

ALADE, I.O; RAHMAN, M. A. A; SALEH, T. A. Modeling and prediction of the specific heat capacity of Al₂O₃/water nanofluids using hybrid genetic algorithm/support vector regression model. **Nano-Structures & Nano-Objects**, v. 17, p. 103 – 111, 2019.

ALFADDA, A; RAHMAN, S; PIPATTANASOMPORN, M. Solar irradiance forecast using aerosols measurements: A data driven approach. **Solar Energy**. V. 170, p. 924 – 939, 2018.

AMORIM NETO, J. P. et al. Analysis and comparison between regression models for temperature estimation of solar collectors operating with nanofluids. In: PROCEEDINGS OF THE XL IBERO-LATIN-AMERICAN CONGRESS ON COMPUTATIONAL METHODS IN ENGINEERING, 40., 2019, Natal. **Anais [...]**. Natal: ABMEC, 2019. p. 1 – 12.

BANDARRA FILHO, E. P. et al. Experimental investigation of a silver nanoparticle-based direct absorption solar thermal system. **Energy Conversion and Management**, v. 84, p. 261 - 267, 2014.

BAZDIDI-TEHRANI, F; KHABAZIPUR, A; VASEFI, S. I. Flow and heat transfer analysis of TiO₂/water nanofluid in a ribbed flat-plate solar collector. **Renewable Energy**, v. 122, p. 406 - 418, 2018.

BEICKER, C. L. I. et al. Experimental study of photothermal conversion using gold/water and MWCNT/water nanofluids. **Solar Energy Materials and Solar Cells**, v. 188, p. 51 - 65, 2018.

BUONOMO, B; MANCA, O; MARINELLI, L; NARDINI, S. Effect of temperature and sonication time on nanofluid thermal conductivity measurements by nano-flash method. **Applied Thermal Engineering**, v. 91, p. 181 - 190, 2015.

CHOI, U.S. Enhancing thermal conductivity of fluids with nanoparticles. In: PROCEEDINGS OF THE ASME INTERNATIONAL MECHANICAL ENGINEERING CONGRESS & EXPOSITION, 1995, San Francisco. **Anais [...]**. San Francisco: Master, 1995. p. 99-103.

COLANGELO, G. et al. Experimental test of an innovative high concentration nanofluid solar collector. **Applied Energy**, v. 154, p. 874 - 881, 2015.

DONG, B; CAO, C; LEE, S. E. Applying support vector machines to predict building energy consumption in tropical region. **Energy and Buildings**, v. 37, p. 545 – 553, 2005.

EBRAHIMI-MOGHADAM, A. et al. Using artificial neural network and quadratic algorithm for minimizing entropy generation of Al₂O₃-EG/W nanofluid flow inside parabolic trough solar collector. **Renewable Energy**, v. 129, p. 473 - 485, 2018.

EL-BAZ, W; TZSCHEUTSCHLER, P; WAGNER, U. Day-ahead probabilistic PV generation forecast for buildings energy management systems. **Solar Energy**, v. 171, p. 478 – 490, 2018.

FU, Y. et al. Investigation on enhancing effects of Au nanoparticles on solar steam generation in graphene oxide nanofluids. **Applied Thermal Engineering**, v. 114, p. 961 - 968, 2017.

JAMES, G. et al. **An Introduction to Statistical Learning: with Applications in R**. New York: Springer, 2013.

JIN, H. et al. Photothermal conversion efficiency of nanofluids: an experimental and numerical study. : An experimental and numerical study. **Solar Energy**, v. 139, p. 278 - 289, 2016.

KARAMI, M. Experimental investigation of first and second laws in a direct absorption solar collector using hybrid Fe₃O₄/SiO₂ nanofluid. **Journal of Thermal Analysis and Calorimetry**, v. 136, n. 2, p. 661 - 671, 2018.

KAYA, H; ARSLAN, K; ELTUGRAL, N. Experimental investigation of thermal performance of an evacuated U-Tube solar collector with ZnO/Ethylene glycol-pure water nanofluids. **Renewable Energy**, v. 122, p. 329 - 338, 2018.

KHEDKAR, R. S; SHRIVASTAVA, N; SONAWANE, S. S; WASEWAR, K. L. Experimental investigation and theoretical determination of thermal conductivity and viscosity of TiO₂-ethylene glycol nanofluid. **Interational Communications in Heat and Mass Transfer**, v. 73, p. 54 - 61, 2016.

LI, Q. et al. Applying support vector machine to predict hourly cooling load in the building. **Applied Energy**, v. 86, p. 2249 - 2256, 2009.

MAHBUBUL, I. M. et al. Carbon nanotube nanofluid in enhancing the efficiency of evacuated tube solar collector. **Renewable Energy**, v. 121, p. 36 - 44, 2018.

MEHRALI, M. et al. Effect of specific surface area on convective heat transfer of graphene nanoplatelet aqueous nanofluids. **Experimental Thermal and Fluid Science**, v. 68, p. 100 - 108, 2015.

OLIVEIRA, G. A. **Síntese e caracterização de nanofluidos de prata**. 121 f. Tese (Mestrado) - Curso de Engenharia Mecânica, Universidade Federal de Uberlândia, Uberlândia, 2012.

OZSOY, A; CORUMLU, V. Thermal performance of a thermosyphon heat pipe evacuated tube solar collector using silver-water nanofluid for commercial applications. **Renewable Energy**, v. 122, p. 26 - 34, 2018.

PAK, B. C; CHO, Y. I. Hydrodynamic and heat transfer study of dispersed fluids with submicron metallic oxide particles. **Experimental Heat Transfer**, v. 11, n. 2, p. 151 - 170, 1998.

RANGA BABU J. A. et al. Thermodynamic analysis of hybrid nanofluid based solar flat plate collector. **World Journal of Engineering**, v. 15, n. 1, p.27 - 39, 2018.

ROCHA, P. A. C. et al. A review on nanofluids: preparation methods and applications. **Tchê Química**, v. 16, n. 31, p.365 - 380, 2019.

SHARAFELDIN, M. A; GRÓF, G. Evacuated tube solar collector performance using CeO₂/water nanofluid. **Journal of Cleaner Production**, v. 185, p. 347 - 356, 2018.

SHIN, D; BANERJEE, D. Enhanced Specific Heat of Silica Nanofluid. **Journal of Heat Transfer**, v. 133, n. 2, p. 14 – 17, 2010.

SREEKUMAR, S. et al. Investigation on influence of antimony tin oxide/silver nanofluid on direct absorption parabolic solar collector. **Journal of Cleaner Production**, v. 249, p. 119378 – 119396, 2020.

SUMAN, S; KHAN, M. K; PATHAK, M. Performance enhancement of solar collectors—A review. **Renewable and Sustainable Energy Reviews**, v. 49, p. 192 - 210, 2015.

SURESH, S. et al. Synthesis of Al₂O₃–Cu/water hybrid nanofluids using two step method and its thermo physical properties. **Colloids and Surfaces A: Physicochemical and Engineering Aspects**, v. 388, p. 41 - 48, 2011.

VOYANT, C. et al. Machine learning methods for solar radiation forecasting: A review. **Renewable Energy**, v. 105, p.569 - 582, 2017.

WOLE-OSHO, I. et al. An experimental investigation into the effect of particle mixture ratio on specific heat capacity and dynamic viscosity of Al₂O₃-ZnO hybrid nanofluids. **Powder Technology**, v. 363, p. 699 - 716, 2020.

YU, X; XUAN, Y. Investigation on thermo-optical properties of CuO/Ag plasmonic nanofluids. **Solar Energy**, v. 160, p. 200 - 207, 2018.