

Universidade Federal Rural do Semi-Árido
Universidade do Estado do Rio Grande do Norte

Programa de Pós-Graduação em Ciência da
Computação

Dissertação de Mestrado

Estimação e Modelagem Preditiva de Recursos
Hídricos, Usando Sequencias de Dados de
Sensoriamento Remoto, obtidos em Tempo de Lapso

Mestrando

Samuel Alves Araújo

Orientador

Dr. Dario José Aloise

Co-Orientador

Dr. Harold Ivan Angulo Bustos

Mossoró - RN

Maio - 2016

**Catálogo da Publicação na Fonte.
Universidade do Estado do Rio Grande do Norte.**

Araújo, Samuel Alves

Estimação e modelagem preditiva de recursos hídricos, usando sequências de dados de sensoriamento remoto, obtidos em tempo de lapso. / Samuel Alves Araújo. - Mossoró/RN, 2016.

63 p.

Orientador: Prof. Dr. Dario José Aloise

Dissertação (Mestrado em Ciência da Computação). Universidade do Estado do Rio Grande do Norte. Universidade Federal Rural do Semi-Árido. Programa de Pós-graduação em Ciência da Computação

1. Sensoriamento remoto. 2. Séries temporais. 3. Desertificação.
4. Redes neurais. I. Aloise, Dário José. II. Universidade do Estado do Rio Grande do Norte. III. Título.

UERN/BC

CDD 616.722

Samuel Alves Araújo

**Estimação e Modelagem Preditiva de Recursos
Hídricos, Usando Sequencias de Dados de
Sensoriamento Remoto, obtidos em Tempo de Lapso**

Dissertação de Mestrado submetida ao Programa de Pós-graduação em Ciência da Computação da Universidade do Estado do Rio Grande do Norte e Universidade Federal Rural do Semi-Árido como parte dos requisitos necessários para obtenção do grau de Mestre em Ciência da Computação.

Orientador: Prof. Dr. Dario José Aloise

Co-orientador: Prof. Dr. Harold Ivan Angulo Bustos

MOSSORÓ

2016

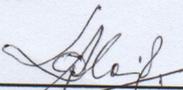
SAMUEL ALVES ARAÚJO

**ESTIMAÇÃO E MODELAGEM PREDITIVA DE RECURSOS
HÍDRICOS, USANDO SEQUENCIAS DE DADOS DE
SENSORIAMENTO REMOTO, OBTIDOS EM TEMPO DE
LAPS.**

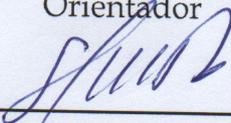
Dissertação apresentada ao Programa de Pós-Graduação em Ciência da Computação para a obtenção do título de Mestre em Ciência da Computação.

APROVADA EM: 31/05/2016.

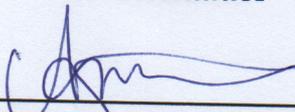
BANCA EXAMINADORA



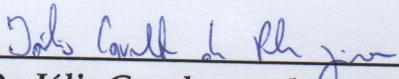
Dr. Dario José Aloise - UERN
Orientador



Dr. Harold Ivan Angulo Bustos - UERN
Co-orientador



Dr. Araken De Medeiros Santos - UFERSA
Avaliador do Programa



**Dr. Iális Cavalcante de Paula Júnior -
UFC**
Avaliador Externo

Agradecimentos

É difícil agradecer todas as pessoas que de algum modo, nos momentos serenos e ou apreensivos, fizeram ou fazem parte da minha vida, por isso primeiramente agradeço à todos de coração.

Agradeço aos meus pais, pela determinação e luta na minha formação e da minha irmã.

Agradeço ao amigo Lino, companheiro de laboratório.

Agradeço aos meus colegas de classe e com certeza futuros excelentes profissionais.

Agradeço aos professores que desempenharam com dedicação as aulas ministradas.

Agradeço à minha querida e amável secretária Rosita, que sempre esteve do meu lado e atenciosamente atendeu aos meus telefonemas, whatsapp e e-mails.

Agradeço à CAPES, pelo financiamento deste trabalho.

E finalmente agradeço a Deus, por proporcionar estes agradecimentos à todos que tornaram minha vida mais afetuosa, além de ter me dado uma família maravilhosa e amigos sinceros. Por isso lutar, conquistar, vencer e até mesmo cair e perder, e o principal, viver é o meu modo de agradecer sempre.

*"Não vos amoldeis às estruturas deste mundo,
mas transformai-vos pela renovação da mente,
a fim de distinguir qual é a vontade de Deus:
o que é bom, o que lhe é agradável, o que é perfeito."
(Bíblia Sagrada, Romanos 12, 2)*

Resumo

Os recursos hídricos são utilizados em todo o mundo com distintas finalidades, entre as quais se destacam o abastecimento de água, a geração de energia, a irrigação, e na navegação. No entanto, nas últimas décadas, esse precioso recurso vem sendo ameaçado pelas ações indevidas do homem. Para melhor direcionar os recursos na prevenção e na mitigação dos efeitos causados pela falta deste recurso, se faz necessário o desenvolvimento de métodos confiáveis de previsão. A pesquisa explana dois métodos de previsão inteligente, baseado em técnicas de aprendizagem de máquina (redes neurais, árvore de decisão), para estimar modelos preditivos 2D, visando inferir mudanças futuras dos recursos hídricos, a partir das informações extraídas do histórico de uma série temporal de imagens de sensoriamento remoto NDVI (*Normal Difference Vegetation Index*), obtida do *Center Space Research* da *University of Texas*, Austin. Previsões acuradas de tais recursos naturais podem ter grande impacto e relevância para a sociedade, haja vista que a estimação precisa do comportamento futuro desses recursos, pode orientar às autoridades no processo da tomada de decisão, em se tratando de prever e mitigar possíveis desastres ambientais e socioambientais, decorrentes de alterações climáticas produzidas pelo aquecimento global, reduzindo-se assim os custos operacionais no processo.

Palavras-chaves: Sensoriamento remoto, séries temporais, desertificação, previsão, predição, redes neurais, árvores de decisão.

Sumário

	Lista de ilustrações	11
	Lista de tabelas	13
1	INTRODUÇÃO	15
2	REFERENCIAL TEÓRICO	17
2.1	Sensoriamento Remoto	17
2.1.1	Histórico	17
2.1.2	Princípios Físicos	19
2.1.3	Sistemas Sensores	21
2.1.4	Representação Vetorial das Imagens	22
2.1.5	Representação Matricial das Imagens	22
2.2	Árvore de Decisao	23
2.2.1	Escolha do Melhor Atributo	25
2.2.2	Ganho de Informação	25
2.2.3	Razão Ganho	26
2.3	Redes Neurais	27
2.3.1	Princípios Básicos	27
2.3.2	Modelo Básico de um Neurônio Artificial	27
2.3.3	Função de Ativação	28
2.3.4	Arquitetura de Redes Neurais	30
2.3.5	Perceptron Multicamadas	31
2.3.6	Aprendizagem de Redes Neurais	31
2.3.7	Levenberg-Marquadt	33
2.4	Transformadas de Imagens	34
2.4.1	Transformada Discreta do Cosseno (DCT – <i>Discrete Cosine Transform</i>)	34
2.4.2	Wavelets	36
2.4.3	Transformada Wavelet Discreta – DWT	38
2.4.4	Transformada Wavelet Bidimensional	40
3	TRABALHOS RELACIONADOS	41
4	ESTRATÉGIAS PROPOSTAS	43
4.0.1	Predição de Pixel	44
4.0.2	Predição no Domínio do Espaço	44
4.0.3	Predição no Domínio da Transformada DCT	45

4.0.4	Predição no Domínio Híbrido Wavelet e DCT	45
5	MATERIAIS E MÉTODOS	47
5.1	Ferramentas Computacionais	47
5.2	Dados Utilizados	47
5.2.1	Imagens Sintéticas	47
5.2.2	Imagens de Sensoriamento Remoto	48
5.2.3	Metodologia Proposta	50
5.2.4	Metodologia de Validação	50
6	RESULTADOS E DISCUSSÃO	53
6.0.1	Resultados com Imagens Sintéticas	53
6.0.2	Resultados com Imagens de Sensoriamento Remoto	56
6.0.3	Considerações Sobre os Resultados	59
7	CONCLUSÕES	61
7.0.1	Perpectivas Futuras	61
	Referências	63

Lista de ilustrações

Figura 1 – Sistema de Sensoriamento Remoto (KUMAR; ALI; HAMMED, 2012)	20
Figura 2 – Componentes de um Sistema Sensor. Fonte: Elaborada pelo autor	21
Figura 3 – Elementos da representação vetorial	22
Figura 4 – Exemplo de uma árvore de decisão	24
Figura 5 – Exemplo de um caminho percorrido	25
Figura 6 – Modelo não-linear de um neurônio (HAYKIN, 2001).	28
Figura 7 – Funções de ativação: (a) Limiar, (b) Linear por partes e (c) Sigmóide.	29
Figura 8 – (a) Rede neural alimentada adiante e (b) Rede recorrente (HAYKIN, 2001).	30
Figura 9 – Série temporal representada por variação nos níveis de cinza. Cada pixel da série corresponde ao mesmo local (i, j), formando uma função unidimensional.	44
Figura 10 – Série temporal de imagens sintéticas com as seguintes figuras geométricas: Uma bola crescente no canto superior esquerdo; uma bola com variação nos níveis de cinza no canto superior direito; uma bola decrescente no canto inferior direito; uma bola deslizante no canto inferior esquerdo.	48
Figura 11 – Série temporal de imagens da área do Texas e regiões envolventes.	49
Figura 12 – Imagem do Google da região da Cidade de Fort Smith e do Rio Arkansas River.	49
Figura 13 – Série temporal de imagens recortada do Rio Arkansas River.	50
Figura 14 – Imagens resultantes da predição de pixel feita pela árvore de decisão da 13 ^a sequência. As simulações do domínio wavelet/DCT foram feitas no nível de resolução 1. A fusão da imagem real com as imagens preditas destaca as diferenças nas cores verde e magenta.	53
Figura 15 – Imagens resultantes da predição de pixel feita pela rede neural da 13 ^a sequência. As simulações do domínio wavelet/DCT foram feitas no nível de resolução 1. A fusão da imagem real com as imagens preditas destaca as diferenças nas cores verde e magenta.	54
Figura 16 – Imagens resultantes da predição de pixel feita pela árvore de decisão da 14 ^a sequência. As simulações do domínio wavelet/DCT foram feitas no nível de resolução 1. A fusão da imagem real com as imagens preditas destaca as diferenças nas cores verde e magenta.	54

Figura 17 – Imagens resultantes da predição de pixel feita pela rede neural da 14 ^a sequência. As simulações do domínio wavelet/DCT foram feitas no nível de resolução 1. A fusão da imagem real com as imagens preditas destaca as diferenças nas cores verde e magenta.	55
Figura 18 – Imagens resultantes da predição de pixel feita pela árvore de decisão da 15 ^a sequência. As simulações do domínio wavelet/DCT foram feitas no nível de resolução 1. A fusão da imagem real com as imagens preditas destaca as diferenças nas cores verde e magenta.	55
Figura 19 – Imagens resultantes da predição de pixel feita pela rede neural da 15 ^a sequência. As simulações do domínio wavelet/DCT foram feitas no nível de resolução 1. A fusão da imagem real com as imagens preditas destaca as diferenças nas cores verde e magenta.	56
Figura 20 – Imagens resultantes da predição de pixel feita pela rede neural e pela árvore de decisão da 11 ^a sequência. As simulações do domínio wavelet/DCT foram feitas no nível de resolução 1.	57
Figura 21 – Imagens resultantes da predição de pixel feita pela rede neural e pela árvore de decisão da 12 ^a sequência. As simulações do domínio wavelet/DCT foram feitas no nível de resolução 1.	57
Figura 22 – Imagens resultantes da predição de pixel feita pela rede neural e pela árvore de decisão da 13 ^a sequência. As simulações do domínio wavelet/DCT foram feitas no nível de resolução 1.	57
Figura 23 – Imagens resultantes da predição de pixel feita pela rede neural e pela árvore de decisão da 14 ^a sequência. As simulações do domínio wavelet/DCT foram feitas no nível de resolução 1.	58
Figura 24 – Imagens resultantes da predição de pixel feita pela rede neural e pela árvore de decisão da 15 ^a sequência. As simulações do domínio wavelet/DCT foram feitas no nível de resolução 1.	58

Lista de tabelas

Tabela 1 – Erro MAE da predição de pixel das imagens 13, 14 e 15 com a Árvore de Decisão.	56
Tabela 2 – Erro MAE da predição de pixel das imagens 13, 14 e 15 com a Rede Neural.	56
Tabela 3 – Erros MAE % das predições de pixel feitas com a rede neural.	58
Tabela 4 – Erros MAE % das predições de pixel feitas com a árvore de decisão. . .	59

1 Introdução

Os recursos hídricos são destinados para as mais diversas finalidades, entre as quais se destacam o abastecimento de água, a geração de energia, a navegação, a agricultura e a harmonia paisagística (SPERLING, 1993).

Desde que se tornou parte dominante dos sistema, o homem tem apresentado comportamentos com tendências contrárias à manutenção dos recursos hídricos. Não podendo criar as fontes que satisfazem suas necessidades fora do sistema ecológico, o homem esbanja e destrói os recursos disponíveis. O principal impacto exercido pelo homem é o consumo em ritmo acelerado do que aquele no qual ele podem ser renovados pelo sistema ecológico. (TRABALHO, 1995)

Com o aumento populacional e das atividades econômicas, muitos países atingem rapidamente condições de escassez de água ou se defrontam com limites para o desenvolvimento econômico. Nos últimos 60 anos, a população mundial duplicou, enquanto o consumo de água multiplicou-se por sete. Da água disponível no planeta, apenas 1% da água está disponível para o consumo. O Brasil detém 8% de toda essa reserva de água, sendo 80% da água doce do país encontrada na região Amazônica, ficando os restantes 20% para o restante do território brasileiro onde se concentram 95% da população (ASSÍS, 1998).

A Região Nordeste do Brasil sofre com a falta de água e necessita constantemente monitorar suas reservas de água. A região também apresenta regiões em processo de desertificação e suscetíveis à desertificação, segundo o Ministério do Meio Ambiente (MMA, 2006).

Segundo alguns especialistas, o principal causa da crise hídrica é o mau gerenciamento desses recursos (ARAÚJO, 2016). Para Somlyódy e Varis (2006), o agravamento e a complexidade da crise da água decorrem de problemas reais de disponibilidade e aumento da demanda, e de um processo de gestão ainda setorial e de resposta a crises e problemas sem atitude preditiva e abordagem sistêmica. tundISI e BARBOSA (2008) acentuam a necessidade de uma abordagem sistêmica, integrada e preditiva na gestão das águas com uma descentralização para a bacia hidrográfica. Segundo esses autores, uma gestão preditiva, utilizada como instrumento de gestão, pode ser uma das formas mais eficazes de enfrentar o problema de escassez de água.

A proposta principal deste trabalho é o uso de árvores de decisão para predições de séries temporais. É possível fazer predições para qualquer padrão de uma imagem de sensoriamento remoto, a escolha da desertificação e dos problema hídricos é pontual, pois sabe-se que esse evento se propaga, através da ação humana (i.e. com áreas degradadas

por (i) prática de pecuária; (ii) prática de agricultura de sequeiro, (iii) pastoreio e (iv) por irrigação) ou processo natural. Avaliar quantitativamente a estratégia da solução proposta para a resolução do problema da estimação preditiva entre o modelo real e o estimado. Comparar a eficácia do método com outras de forma de predição a definir quais dos dois métodos possuem menor erro quando aplicada ao problema em questão. Sendo assim, torna-se possível analisar o impacto de uma dada ação externa (intervenção humana) sobre uma determinada área que tem um padrão natural.

Os testes serão realizados a partir de séries de imagens de sensoriamento remoto e artificiais que refletem a mudança no ambiente. Será avaliada a acurácia da aplicação em diversos domínios. Como, por exemplo, os domínios do espaço (*pixel a pixel*) e da frequência.

O trabalho consta com o Capítulo 2 que faz uma breve revisão sobre imagens de sensoriamento remoto, dos algoritmos de regressão e compressão que serão utilizados.

No Capítulo 3 são apresentados trabalhos relacionados que mostram outros autores que trabalham com a mesma problemática.

O Capítulo 4 propõe estratégias de predição de séries temporais de imagens, que são usadas nas séries temporais de imagens de sensoriamento remoto e imagens sintéticas.

O Capítulo 5 são demonstradas as formas de implementação e os parâmetros ajustáveis.

O resultados deste trabalho e perspectivas futuras são discutidas no Capítulo 6 e no Capítulo 7.

2 Referencial Teórico

Nesse capítulo serão discutidos temas referentes ao contexto histórico das tecnologias de sensoriamento remoto 2.1.1, dos princípios físicos 2.1.2, dos sensores usados para obtenção de imagens do solo 2.1.3, sobre as redes neurais 2.1.4, dos algoritmos de aprendizado 2.1.5 e sobre a transformada discreta do cosseno 2.3.

2.1 Sensoriamento Remoto

Sensoriamento remoto, que, de acordo com [Moreira \(2005\)](#) foi um termo cunhado na década de 60 por Evelyn L. Pruitt e colaboradores, é uma das mais bem-sucedidas tecnologias de coleta automática de dados para o levantamento e monitoração dos recursos terrestres em escala global.

2.1.1 Histórico

O Sensoriamento Remoto remete às tecnologias de obtenção de imagens da superfície da terra de forma remota (*i.e* sem contato físico entre o sensor que capta as imagens e o objeto). O Sensoriamento Remoto é uma das mais bem sucedidas tecnologias de coleta de dados para o levantamento e monitoração dos recursos terrestres em escala global ([MENESES; SANO; ASSAD, 1991](#)).

O sensorialmente remoto teve sua origem nos anos de 1960 devido a corrida espacial. O constante desenvolvimento de foguetes lançadores de satélites possibilitou colocar no espaço satélites artificiais para várias finalidades. No Brasil, as pesquisas sobre sensoriamento remoto começaram na década de 90 com o objetivo de monitorar queimadas na Floresta Amazônica.

No Brasil, o Instituto Nacional de Pesquisas Espaciais (INPE) teve uma ação decisiva na consolidação do sensoriamento remoto como uma tecnologia de uso em escala nacional, projetando o Brasil como a nação pioneira no hemisfério sul a dominar essa tecnologia. Segundo [Barrett \(2013\)](#), a evolução do sensoriamento remoto está ligada a alguns dos principais eventos abaixo:

- 1687: O livro Principia de Isaac Newton sumariza as leis básicas da mecânica
- 1826: Joseph Nicephore Niepce tira a primeira fotografia
- 1839: Louis M. Daguerre inventa o daguerreotipo para impressão em positivo da fotografia

- 1839: William Henry Fox Talbot inventa o processo negativo/positivo chamado Calótipo
- 1855: James Clerk Maxwell postula a teoria aditiva da cor
- 1858: Gaspard Felix Tournachon tira uma fotografia aérea a partir de um balão
- 1860: James Clerk Maxwell desenvolve a teoria eletromagnética ondulatória
- 1903: Alfred Maul patenteia a câmera para obter fotografias a partir de um foguete
- 1926: Robert Goddard lança o primeiro foguete movido a combustível líquido
- 1940: Invenção do RADAR
- 1950: Invenção do sensoriamento remoto no infravermelho termal pelos militares
- 1955 a 1956: Programa Norte-Americano Genetrix de reconhecimento por balão
- 1956 a 1960: Programa da Agência Central de Inteligência (CIA) de reconhecimento com aviões U-2
- 1957: A União Soviética lança o satélite Sputnik
- 1958: Os Estados Unidos lançam o satélite Explorer 1
- 1960: Ênfase principal no processamento visual de imagens
- 1960: Primeiro International Symposium on *Remote Sensing of Environment* em Ann Arbor, Michigan
- 1960: Ativação do Laboratório para Sensoriamento Remoto Agrícola de Purdue (LARS - *Purdue Laboratory for Agricultural Remote Sensing*)
- 1960: Iniciou-se o processamento de imagens digitais no LARS, em Berkeley, Kansas, no ERIM
- 1960: O termo remote sensing (sensoriamento remoto) é introduzido por Evelyn L. Pruitt e pelo pessoal do U. S. Office of Naval Research
- 1969: *Remote Sensing of Environment* (Elsevier)
- 1969: Início das atividades de sensoriamento remoto no INPE
- 1972: ERTS-1 (Earth Resources Technology Satellite, posteriormente rebatizado como Landsat) lançado (NASA)
- 1972: Implantação do Curso de Mestrado em Sensoriamento Remoto, no INPE

- 1975: ERTS-2 lançado (renomeado para Landsat-2)
- 1977: METEOSAT-1 lançado (European Space Agency)
- 1978: Landsat-3 lançado (NASA)
- 1978: Primeiro Simpósio Brasileiro de Sensoriamento Remoto
- 1982: Lançado o Landsat-4 com o Thematic Mapper (TM) e o MSS
- 1984: Lançado o Landsat-5 - Thematic Mapper e MSS (NASA)
- 1984: Lançado o Space Shuttle Imaging Radar (SIR-A) (NASA)
- 1990: Maturidade da fotogrametria digital computadorizada (soft-copy)
- 1991: Lançado o ERS-1 (European Space Agency)
- 1993: O Landsat-6 não atinge sua órbita (EOSAT, Inc.)
- 1993: Lançado o SPOT-3 (Spot Image, Inc.)
- 1995: Lançado o ERS-2 (European Space Agency)
- 1998: Criação do Curso de Doutorado em Sensoriamento Remoto, no INPE
- 1999: Lançado o Landsat-7 ETM+
- 1999: Lançado o CBERS-1 (China-Brazil Earth Resources Satellite)
- 2002: Introdução dos algoritmos de segmentação de imagens orientada ao objeto
- 2003: Lançado o OrbView-3 (ORBIMAGE, Inc.)
- 2003: Lançado o CBERS-2 (China-Brazil Earth Resources Satellite)
- 2005: Google Earth usa dados da DigitalGlobe e do TM/Landsat
- 2007: Lançado o CBERS-2B (China-Brazil Earth Resources Satellite)

2.1.2 Princípios Físicos

Segundo [Kumar, Ali e Hammed \(2012\)](#), a radiação eletromagnética ao incidir sobre a superfície de um material, parte dela será refletida por esta superfície, parte será absorvida e parte pode ser transmitida caso a matéria possua alguma transparência. A soma desses três componentes será igual à intensidade da energia incidente.

Esse modelo serviu de base para aplicações modernas, como a captação de imagens de sensoriamento remoto. Onde, os elementos fundamentais para o funcionamento de um sistema de sensoriamento remoto, são:

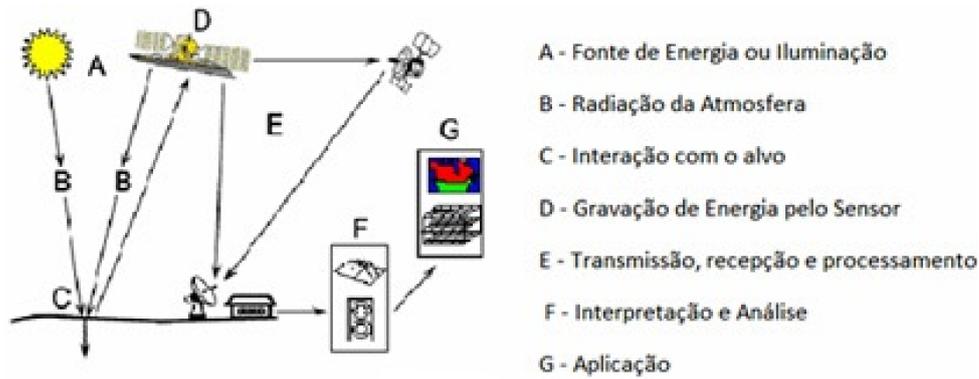


Figura 1 – Sistema de Sensoriamento Remoto (KUMAR; ALI; HAMMED, 2012)

- O objeto de estudo;
- A radiação eletromagnética;
- Um sensor.

A Figura 1, procura mostrar como o sensor utiliza os feixes de luz (radiação) para emitir e receber sinais, que são recebidos, processados e interpretados por sistemas computacionais, o resultado deste processo é uma imagem sintetizada conforme os padrões de ondas que foram observadas durante a captação. As diferentes cores em uma imagem sintetizada são, na verdade, radiação eletromagnética de comprimentos de onda diferentes. A cor azul corresponde ao intervalo de 0,35 a 0,50 nanômetros, a do verde vai de 0,50 a 0,62 nanômetros e a do vermelho, de 0,62 a 0,70 nanômetros. Estes intervalos também são conhecidos como regiões. Abaixo do vermelho, está a região do infravermelho, e logo acima do azul está o ultravioleta (ambos imperceptíveis ao olho humano).

Os sensores remotos medem as intensidades do espectro eletromagnético e, com essas medidas, obtém imagens nas regiões do visível (azul, verde e vermelho) ao infravermelho medem a intensidade da radiação eletromagnética refletida em cada intervalo pré-determinado de comprimento de onda.

A captação de imagens de Sensoriamento Remoto só é possível graças ao comportamento onda/partícula da radiação eletromagnética, que permite a sua propagação tanto no vácuo quanto usando o meio físico (ar).

E, segundo [Meneses, Sano e Assad \(1991\)](#) a aquisição dessas imagens, pode ser feito em três níveis distintos:

- Nível terrestre: São feitas as pesquisas básicas sobre como os objetos absorvem, refletem e emitem radiação. Os resultados destas pesquisas geram informações sobre como os objetos podem ser identificados pelos sensores orbitais. Desta forma é possível identificar áreas de queimadas numa imagem gerada de um satélite,

diferenciar florestas de cidades e de plantações agrícolas e até identificar áreas de vegetação que estejam doentes ou com falta de água.

- Nível sub-orbital: são as também chamadas fotografias aéreas, utilizadas principalmente para produzir mapas. Neste nível operam-se também algumas câmeras de vídeo e radares.
- Nível orbital: estão os balões meteorológicos e os satélites. Os primeiros são utilizados nos estudos do clima e da atmosfera terrestre, assim como em previsões do tempo. Já os satélites também podem produzir imagens para uso meteorológico, mas também são úteis nas áreas de mapeamento e estudo de recursos naturais.

2.1.3 Sistemas Sensores

Os sistemas sensores são dispositivos capazes de detectar e registrar a radiação eletromagnética, em determinada faixa do espectro eletromagnético e gerar informações que possam ser transformadas num produto passível de interpretação, na forma de gráficos ou de tabelas (MOREIRA, 2005).

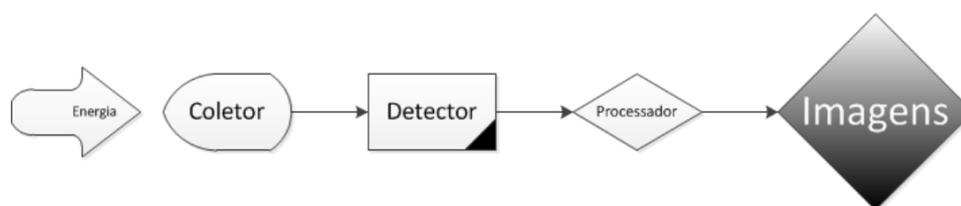


Figura 2 – Componentes de um Sistema Sensor. Fonte: Elaborada pelo autor

Na Figura 2, o coletor recebe a energia através de uma lente e passa informação para o detector que capta a energia coletada de uma determinada faixa do espectro. De posse dessas informações, o processador processa o sinal registrado através do qual se sintetiza uma imagem.

Os sensores podem realizar a captura da radiação refletida de duas formas: passivamente, apenas capturando as radiações que foram emitidas por uma fonte externa; ou ativamente, onde o sensor emite e capta a radiação refletida dos objetos.

A forma de capturar da radiação pode ser feita de duas formas distintas: no domínio espacial, no qual toda a radiação de área é captada de uma só vez como em uma fotografia. E de forma temporal, onde a aquisição da radiação é feita de forma sequencial, como em um vídeo.

2.1.4 Representação Vetorial das Imagens

Camara, Davis e Monteiro (2001) definem o conceito de representação vetorial como a forma reduzida de um elemento ou objeto. Esse elemento pode ser representado de três formas básicas: pontos, linha poligonal, e áreas ou polígonos, como pode ser visto na Figura 3.

- *Ponto* - será um par ordenado (x, y) de coordenadas espaciais. Outros dados não espaciais, denominados atributos, também podem ser arquivados para indicar características do ponto;
- *Linha poligonal* - consiste em um conjunto de pontos conectados. Nas linhas são armazenadas, além das coordenadas dos pontos, informações com a indicação do tipo de linha que está sendo tratada, ou seja, a qual atributo ela está associada;
- *Áreas ou Polígonos* - correspondem à região do plano que é limitada por uma ou mais linhas poligonais conectadas de maneira que o último ponto de uma linha seja o primeiro ponto da próxima linha.

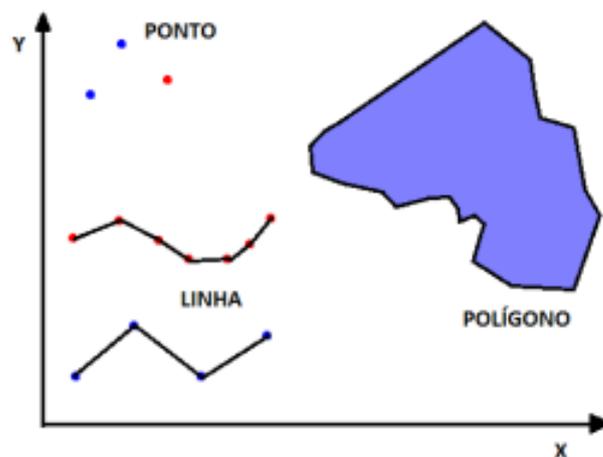


Figura 3 – Elementos da representação vetorial

2.1.5 Representação Matricial das Imagens

As imagens digitais da superfície terrestre que são gravadas por sensores orbitais, são transformadas em dois tipos de produtos: analógico e digital (MOREIRA, 2005). Os produtos analógicos são tratados pelo processo de interpretação visual, como pode ser visto em (MOREIRA, 2005). Os produtos digitais, são tratados por meio de métodos específicos de análise de dados, implementados em computadores, ou seja, essa imagem pode passar por um processo de melhoramento de alguns aspectos de suas feições. Cada pixel de uma imagem possui um valor proporcional à energia eletromagnética refletida ou

emitida 25 pela área da superfície terrestre que possui correlação e esses elementos são armazenados como matrizes. Dentre algumas características importantes das imagens de satélites temos:

- *Resolução Espectral* - corresponde ao número e a largura de bandas do espectro eletromagnético imageadas;
- *Resolução Espacial* - corresponde a menor área da superfície terrestre observada instantaneamente por cada sensor;
- *Resolução Radiométrica* - tem relação com o nível de quantização registrado pelo sistema sensor;
- *Resolução Temporal* - é o intervalo entre duas passagens do satélite pelo mesmo ponto.

2.2 *Árvore de Decisao*

Desde o advento da Inteligência Artificial, temos que os algoritmos de aprendizagem de máquinas vêm sendo utilizados, ganhando mais força depois dos anos 80, para fazer operações referentes a:

- Filtragem de dados;
- Reconstrução de estruturas;
- Compressão de dados;
- Codificação;
- Classificação;
- Predição.

Onde o foco do trabalho recairá sobre a operação de predição, para fazer extrapolações de series temporais.

Segundo [Russel e Norwing \(2003\)](#), a árvore de decisão é uma das formas mais simples e bem sucedidas de algoritmos de aprendizagem. As árvores de decisão pertencem à família de algoritmos TDIDT (*Top Down Induction of Decision Tree*). Tais algoritmos utilizam uma abordagem *dividir para conquistar*, buscando dividir em vários subconjuntos os exemplos utilizados para o treino, até cada um destes subconjuntos pertencer a uma mesma classe, ou até uma das classes ser majoritária ([QUINLAN, 1993](#)).

Uma árvore de decisão pode ser definida recursivamente como:

- Um nó folha que corresponde a uma classe ou;
- Um nó de decisão que contém um teste sobre algum atributo. Para cada resultado do teste existe uma aresta para uma subárvore. Cada subárvore tem a mesma estrutura que a árvore.

O algoritmo ID3 (*Induction of Decision Tree*) é o mais conhecido dentre os algoritmos TDIDT. A árvore é gerada de cima para baixo e em cada nó é escolhido qual atributo deve-se testar. Tal decisão é tomada de forma gulosa, ou seja, a melhor naquele determinado momento (QUINLAN, 2014).

A Figura 4 apresenta a representação de uma árvore de decisão, no qual são testados atributos quantitativos e categóricos.

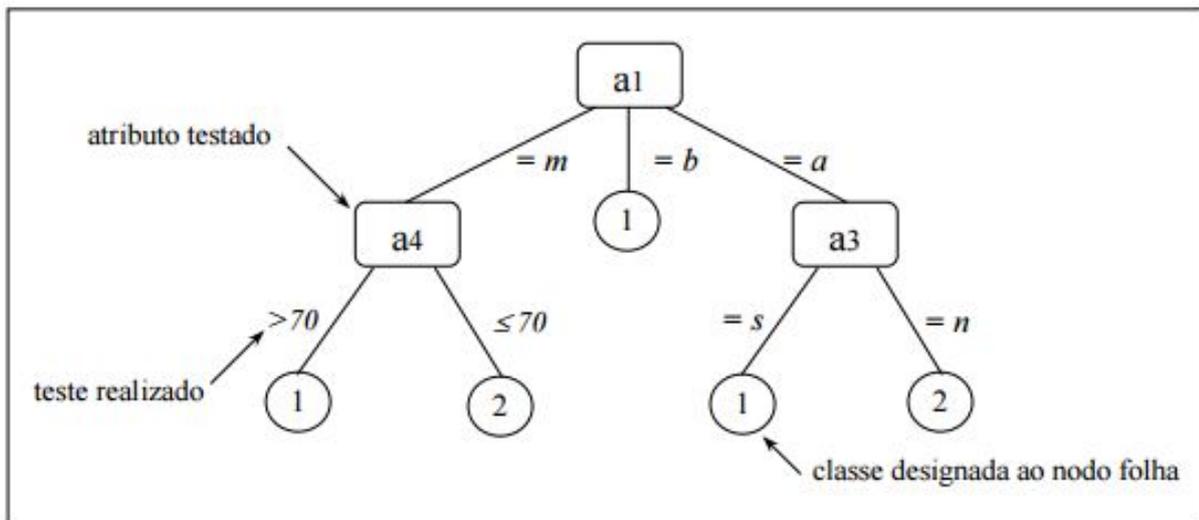


Figura 4 – Exemplo de uma árvore de decisão

Neste exemplo, $a1$, $a3$ e $a4$ representam os atribuídos distribuídos na árvore de acordo com seu nível informativo. Nos arcos são testados os valores dos atributo designado ao nodo a que pertencem. Valores categóricos, são representados por uma igualdade, por exemplo, $= m$, onde m é um valor do atributo. Para valores quantitativos, é testado um intervalo de valor, por exemplo, > 70 , sendo este intervalo obtido através de cálculo. Cada círculo ao final dos ramos da árvore indica a classe associada aos nodos folha.

A classificação ou regressão ocorre ao se percorrer o caminho que se inicia no nodo raiz ($a1$) e se estende até as folhas. Na classificação o valor da folha representa um dado categórico de uma determinada classe. Para a regressão os valores da folhas são quantitativos.

O caminho destacada na Figura 5 indica uma classificação ou regressão. Através do caminho descrito por uma árvore de decisão é possível derivar regras. As árvores e as

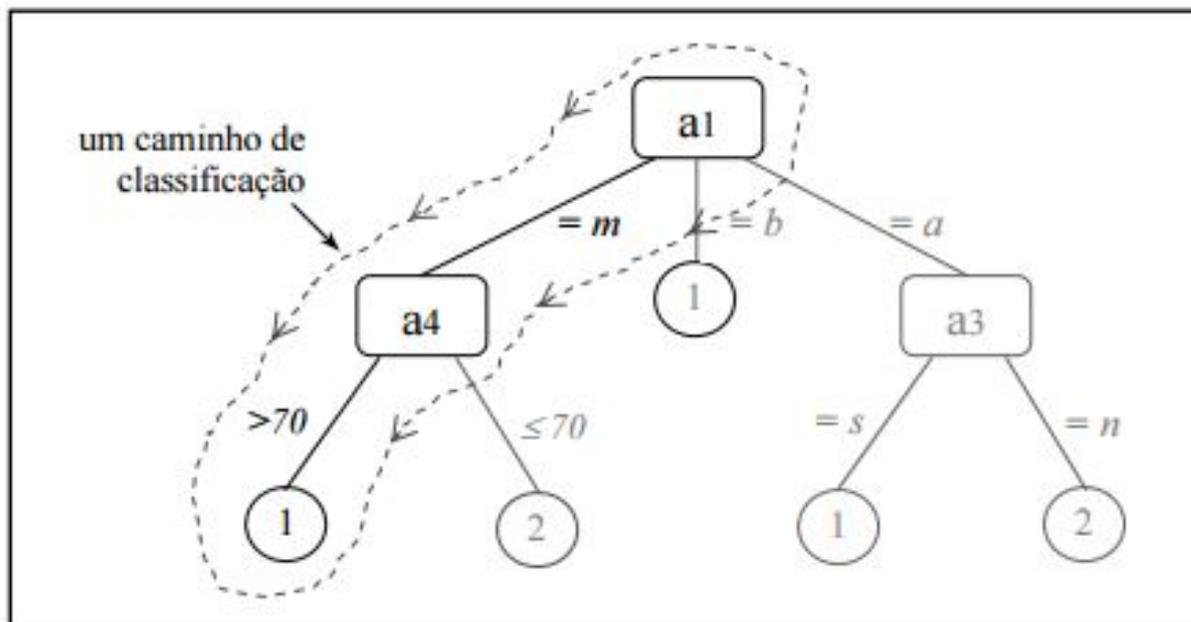


Figura 5 – Exemplo de um caminho percorrido

regras são geralmente utilizadas em conjunto. De acordo com a aplicação as árvores tendem a crescer muito, elas são substituídas pelas regras.

Regra Extraída do caminho destacado na árvore da figura 5, é dada como:

$$\text{se } a1 = m \text{ e se } a4 > 70 \text{ então } 1$$

2.2.1 Escolha do Melhor Atributo

A escolha do melhor atributo ocorre de forma a utilizar aquele que tenha melhor capacidade de isolar e classificar os exemplos. A maioria dos algoritmos de indução da árvore trabalha com uma função de divisão univariável, onde cada nó interno é dividido de acordo com um único atributo. O algoritmo busca o melhor atributo para ser o nó-pai, da árvore ou subárvore, de modo a minimizar ao máximo o grau de impureza dos nós filhos (ZUBEN; ATTUX, 2008).

2.2.2 Ganho de Informação

O ganho de informação é uma das medidas utilizadas para escolher o melhor atributo, o qual usa a entropia como medida de impureza. Para determinar o quão boa é uma condição de teste realizada, é necessário comparar o grau de entropia do nó-pai com o grau de entropia dos nós-filhos. O atributo que gerar uma maior diferença é escolhido como condição de teste. (ZUBEN; ATTUX, 2008).

O ganho é dado pela equação 2.1

$$ganho = entropia - \sum_{j=1}^n \left[\frac{N(v_j)}{N} entropia(v_j) \right] \quad (2.1)$$

onde n é o número de valores do atributo, ou seja, o número de nós-filhos, N é o número total de objetos do nó-pai e $N(v_j)$ é o número de exemplos associados ao nó-filho (v_j). O grau de entropia é definido pela equação 2.1

$$entropia(no) = - \sum_{i=1}^c p(i/no) \times \log_2 [p(i/no)] \quad (2.2)$$

onde $p(i/no)$ é a fração dos registros pertencentes à classe i no nó, e c é o número de classes. A entropia está relacionada a organização da informação, quanto maior a entropia mais uniforme está a distribuição, ou seja, quanto menos a entropia dos nós-filhos menos classes diversas terá naquele nó.

O critério de ganho seleciona como atributo-teste aquele que maximiza o ganho de informação. O grande problema ao se utilizar o ganho de informação é que ele dá preferência a atributos com muitos valores possíveis (ZUBEN; ATTUX, 2008).

Um exemplo claro desse problema ocorreria ao utilizar um atributo totalmente irrelevante, por exemplo, um identificador único. Nesse caso seria criado um nó para cada valor possível e o número de nós seria igual ao número de identificadores. Cada um desses nós teria apenas um exemplo, o qual pertence a uma única classe, ou seja, os exemplos seriam totalmente discriminados. Assim, o valor da entropia seria mínima porque, em cada nó, todos os exemplos, no caso um só, pertencem à mesma classe. Essa divisão geraria um ganho máximo, embora seja totalmente inútil.

2.2.3 Razão Ganho

Quinlan (1993) propôs usar a Razão de Ganho, ou seja, o ganho relativo a entropia de cada nó como critério de avaliação. A razão do ganho é definida pela equação 2.3:

$$razao_ganho(no) = \frac{ganho}{entropia(no)} \quad (2.3)$$

Na equação acima, não existe razão de ganho quando entropia é zero, mas ainda favorece os atributos que possuem menor entropia (ZUBEN; ATTUX, 2008).

2.3 Redes Neurais

2.3.1 Princípios Básicos

O estudo das redes neurais artificiais é motivado pelo fato de que é possível gerar soluções a partir de aprendizado e de generalizar o conhecimento aprendido sem o uso de algoritmos ou regras. Tal abordagem pode ser mais eficiente e eficaz que métodos tradicionais, principalmente em casos onde é necessário ter respostas coerentes para problemas não completamente conhecidos. O problema de previsão de série temporal de sinais AVO - *Amplitude Variation with Offset*, se enquadra neste caso, pois o maior conhecimento obtido sobre o reservatório está restrito a dados sísmicos (BRAGA; FERREIRA; LUDERMIR, 2007).

Redes neurais são sistemas paralelos distribuídos compostos por unidades de processamento simples (neurônios artificiais) que calculam determinadas funções matemáticas (normalmente não-lineares). Tais unidades são dispostas em uma ou mais camadas e interligadas por um grande número de conexões, geralmente unidirecionais. Na maioria dos modelos, essas conexões estão associadas a pesos, os quais armazenam o conhecimento adquirido pelo modelo e servem para ponderar a entrada recebida por cada neurônio da rede (BRAGA; FERREIRA; LUDERMIR, 2007).

Uma rede neural extrai seu poder computacional através, primeiro, de sua estrutura maciçamente paralelamente distribuída e segundo de sua habilidade de aprender e portanto de generalizar. A generalização se refere ao fato de a rede neural produzir saídas adequadas para entradas que não estavam presentes durante o treinamento (aprendizagem). Estas duas capacidades de processamento da informação tornam possível para as redes neurais resolver problemas complexos (HAYKIN, 2001). Comumente, as tarefas principais nas quais as redes neurais se aplicam são: classificação, categorização (agrupamento ou *clustering*), aproximação, previsão e otimização.

As redes neurais também podem ter diversas configurações de topologias e algoritmos de treinamento. O processo de escolha de uma determinada rede neural ou algoritmo de treinamento pode ser baseado no melhor resultado obtido para um conjunto de entradas e saídas já conhecido. Pode-se também otimizar topologia e treinamento por meta-heurísticas e otimização combinatória. Haykin (2001) destaca os seguintes aspectos importantes no projeto de redes neurais: a função de ativação, a arquitetura da rede neural e o aprendizado.

2.3.2 Modelo Básico de um Neurônio Artificial

O neurônio artificial, proposto por McCulloch e Pitts (1943), é uma forma de simulação do neurônio biológico, sendo a unidade básica para o processamento da informação

em uma rede neural. O modelo básico representado pelo diagrama de blocos da Figura 4, que mostra o relacionamento entre os elementos do neurônio artificial.

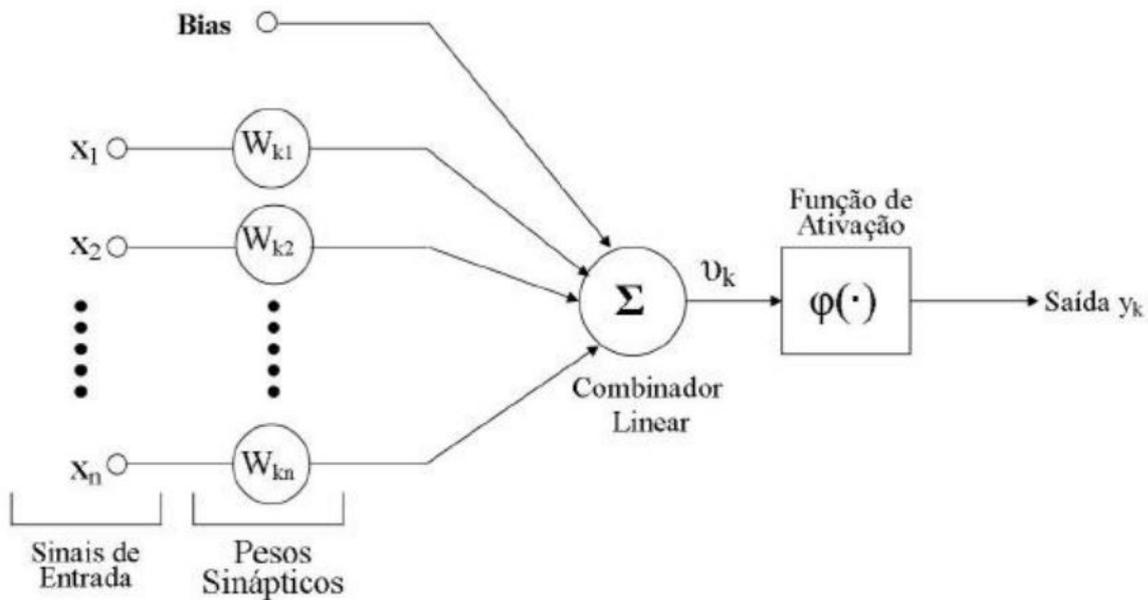


Figura 6 – Modelo não-linear de um neurônio (HAYKIN, 2001).

O neurônio possui os seguintes elementos:

1. Os sinais de entrada X_1, X_2, \dots, X_n .
2. Um conjunto de sinapses com seus pesos sinápticos $W_{k1}, W_{k2}, \dots, W_{km}$. Os pesos sinápticos são representados por W_{kj} , onde k representa o índice do neurônio em questão e j se refere ao terminal de entrada da sinapse a qual o peso sináptico se refere;
3. Um combinador linear u , representado pela soma dos sinais de entrada ponderados pelos pesos sinápticos;
4. Uma função de ativação φ para restringir a amplitude da saída de um neurônio;
5. Um bias b_k , que tem o efeito de aumentar ou diminuir a entrada líquida da função de ativação, dependendo se ele é positivo ou negativo, respectivamente.

2.3.3 Função de Ativação

Matematicamente, o neurônio k é representado pelas seguintes equações:

$$u_k = \sum_{j=1}^m w_{kj} x_j \quad (2.4)$$

$$y_k = \varphi(u_k + b_k) \quad (2.5)$$

Na Equação 2.5, o valor $u_k + b_k$ é denominado potencial de ativação ou campo local induzido v_k . Portanto, temos:

$$v_k = u_k + b_k \quad (2.6)$$

A função de ativação define a saída do neurônio com base no campo local induzido v_k . O resultado é um valor delimitado entre um mínimo e um máximo, geralmente 0 e 1. Segundo Haykin (2001), existem três tipos básicos de função de ativação:

1. Função de Limiar (Degrau), onde:

$$\varphi(v) = \begin{cases} 1 & \text{se } v \geq 0, \\ 0 & \text{se } v < 0 \end{cases} \quad (2.7)$$

2. Função Linear por Partes, onde:

$$\varphi(v) = \begin{cases} 1 & \text{se } v \geq +\frac{1}{2}, \\ v & \text{se } +\frac{1}{2} > v > -\frac{1}{2}, \\ 0 & \text{se } v \leq -\frac{1}{2} \end{cases} \quad (2.8)$$

3. Função Sigmóide, onde:

$$\varphi(v) = \frac{1}{1 + e^{-av}} \quad (2.9)$$

Como mostra a Figura 7.

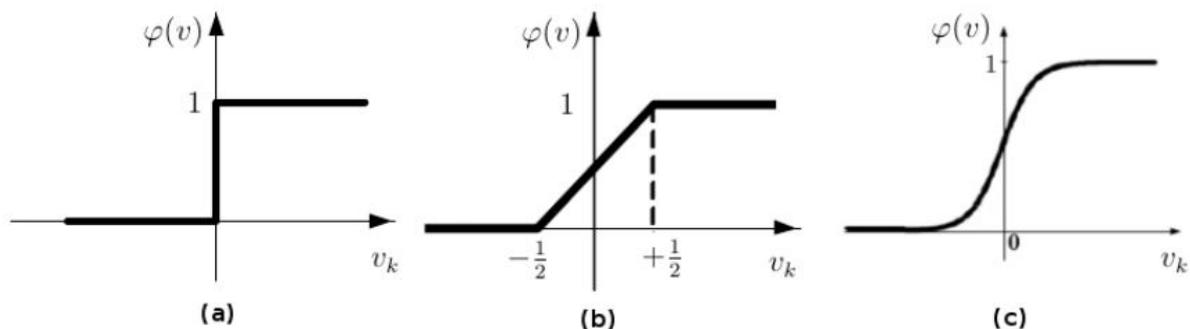


Figura 7 – Funções de ativação: (a) Limiar, (b) Linear por partes e (c) Sigmóide.

2.3.4 Arquitetura de Redes Neurais

Na literatura, diversas arquiteturas de redes neurais têm sido propostas. De fato, o conceito de uma rede de neurônios interligados abre possibilidades para criação de infinitos tipos de configurações com capacidade de aprendizado. Por exemplo, os seres vivos e suas configurações neuronais que são variáveis de espécie para espécie, mas otimizadas para o seu respectivo habitat natural.

Em geral, as topologias são classificadas em dois tipos:

1. Redes Alimentadas Adiante (*Feed-forward networks*): Os neurônios são dispostos em camadas distintas e ordenadas em sequência, sendo o fluxo da informação da camada de entrada em direção à camada de saída. Podem ter, desde 1 até n camadas. As redes *feed-forward* de múltiplas camadas assim como as redes de uma camada, possuem fluxo de informação unidirecional, porém, neste caso, há presença de camadas ocultas, cujos nós computacionais são chamados de neurônios ocultos. Devido ao conjunto extra de conexões sinápticas, e da riqueza de interações neurais, as camadas ocultas são capazes de extrair características complexas do ambiente em que atuam (HAYKIN, 2001).
2. Redes recorrentes: Uma rede neural recorrente se distingue de uma rede neural alimentada adiante por ter pelo menos um laço de realimentação. A presença de laços de realimentação tem um impacto profundo na capacidade de aprendizagem da rede e no seu desempenho. Além disso, os laços de realimentação envolvem o uso de ramos particulares compostos de elementos de atraso unitário, representado por z^{-1} , o que resulta em um comportamento dinâmico não-linear, admitindo-se que a rede neural contenha unidades não-lineares (HAYKIN, 2001).

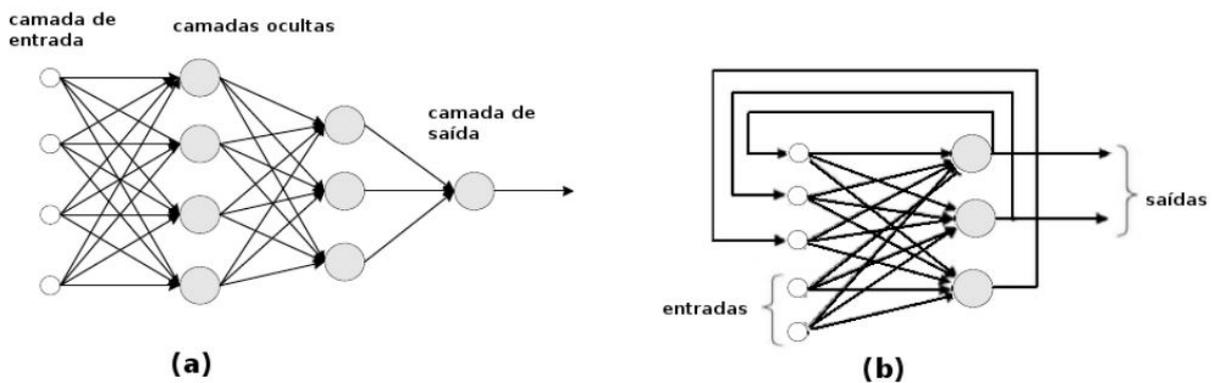


Figura 8 – (a) Rede neural alimentada adiante e (b) Rede recorrente (HAYKIN, 2001).

2.3.5 Perceptron Multicamadas

O modelo proposto por [Rosenblatt \(1958\)](#), conhecido como Perceptron, era composto por uma estrutura de rede, tendo como unidades básicas neurônios MCP (McCulloch e Pitts) e por uma regra de aprendizado. [Rosenblatt \(1958\)](#) também demonstrou que o teorema da convergência do Perceptron, que mostra que um neurônio MCP treinado com o algoritmo do Perceptron sempre converge caso o problema em questão seja linearmente separável ([HAYKIN, 2001](#)).

A rede neural Perceptron de Múltiplas Camadas (MLP - *Multilayer Perceptron*) é um tipo de rede *feed-forward* de múltiplas camadas baseada no modelo Perceptron de [Rosenblatt \(1958\)](#). Redes MLP apresentam um poder computacional maior do que aquele apresentado pelas redes de uma única camada. Em problemas de classificação, por exemplo, MLPs podem lidar com conjuntos de dados que não sejam linearmente separáveis. Teoricamente, redes com duas camadas intermediárias podem implementar qualquer função, seja ela linearmente separável ou não ([BRAGA; FERREIRA; LUDERMIR, 2007](#)).

Abaixo são citadas algumas considerações sobre configurações de MLPs:

- Uma camada intermediária é suficiente para aproximar qualquer função contínua, e duas camadas são suficientes para aproximar qualquer função ([CYBENKO, 1989](#)).
- A utilização de um número maior de camadas que o necessário pode levar a problemas de convergência da rede, já que as camadas intermediárias trabalham com estimativas de erro, as quais, quando em maior quantidade, podem dificultar a convergência global da rede ([BRAGA; FERREIRA; LUDERMIR, 2007](#)).
- Pelo menos uma das camadas deverá ter funções de ativação não-lineares. Assim, as redes MLP se caracterizam pela utilização de funções sigmóides (unipolares ou bipolares) nas camadas intermediárias e sigmóides ou lineares na saída. A utilização de funções puramente lineares em múltiplas camadas resultaria em uma rede de uma única camada, já que transformações lineares sucessivas podem ser descritas como uma única transformação linear ([BRAGA; FERREIRA; LUDERMIR, 2007](#)).
- A definição do número de neurônios em cada uma das camadas da rede é de extrema importância para o seu desempenho, principalmente no que se refere à sua capacidade de generalização. Por outro lado, o superdimensionamento (excesso de neurônios) da rede pode levar a rede a memorizar os dados de treinamento, ao invés de generalizar ([BRAGA; FERREIRA; LUDERMIR, 2007](#)).

2.3.6 Aprendizagem de Redes Neurais

As redes neurais, independentemente de arquitetura, necessitam de um processo de treinamento que vise adaptá-las à solução de problemas. O treinamento é feito com o

ajuste dos parâmetros livres da rede, adaptando-a gradativamente ao ambiente externo.

É importante ressaltar que o conceito de aprendizado está relacionado com a melhoria do desempenho da rede segundo algum critério preestabelecido. O erro quadrático médio da resposta da rede em relação ao conjunto de dados fornecido pelo ambiente, por exemplo, é utilizado como critério de desempenho pelos algoritmos de correção de erros. Assim, quando esses algoritmos são utilizados no treinamento de redes neurais, espera-se que o erro diminua à medida que o aprendizado prossiga.

Há vários algoritmos diferentes para treinamento de redes neurais podendo os mesmos ser agrupados em dois paradigmas principais: aprendizado supervisionado e aprendizado não supervisionado (BRAGA; FERREIRA; LUDERMIR, 2007).

No aprendizado supervisionado, o supervisor (ou professor) é responsável por estimular as entradas da rede por meio de padrões de entrada e observar a saída calculada pela mesma, comparando-a com a saída desejada. Como a resposta da rede é função dos valores atuais do seu conjunto de pesos, estes são ajustados de forma a aproximar a saída da rede da saída desejada. Exemplos de algoritmos de aprendizado supervisionado são a Aprendizagem por Correção de Erros e a Aprendizagem por Reforço.

Na Aprendizagem por Correção de Erros, procura-se minimizar o erro da resposta atual da rede em relação à saída desejada. Já na Aprendizagem por Reforço, o supervisor, mais conhecido como crítico externo, procura maximizar o reforço das ações bem executadas pela rede, caracterizando-se como um processo de tentativa e erro visando maximizar o desempenho da rede.

No aprendizado não-supervisionado, não há professor ou supervisor para acompanhar o processo de aprendizagem. Durante o processo de aprendizagem, os padrões são apresentados continuamente à rede. Caso exista regularidades ou redundâncias nos dados de entrada, há uma tendência de aprendizado na rede. O aprendizado não-supervisionado se aplica a problemas que visam à descoberta de características estatisticamente relevantes nos dados de entrada, por exemplo, a descoberta de agrupamentos ou classes. Exemplos de algoritmos de aprendizagem não-supervisionada são o Aprendizado por Competição e o Aprendizado Hebbiano.

No Aprendizado por Competição, dado um padrão de entrada, este faz com que as unidades de saída disputem entre si para serem ativadas. A unidade de saída vencedora tem seus pesos atualizados no treinamento. No Aprendizado Hebbiano propõe que o peso de uma conexão sináptica deve ser ajustado se houver sincronismo entre os níveis de atividade de entrada e saída. Se dois neurônios, em lados distintos de uma sinapse, são ativados sincronamente, tem-se um fortalecimento dessa sinapse. Entretanto, se os neurônios forem ativados assincronamente, a sinapse será enfraquecida ou mesmo eliminada (BRAGA; FERREIRA; LUDERMIR, 2007).

2.3.7 Levenberg-Marquadt

O algoritmo de treinamento utilizado neste trabalho para predição das séries temporais foi o de Levenberg-Marquadt. Este algoritmo tem sido amplamente utilizado na literatura para problemas gerais envolvendo redes neurais, incluindo redes recorrentes e se enquadra no paradigma de aprendizado supervisionado, pois utiliza dados conhecidos como treinamento para predição de resultados futuros.

O algoritmo de Levenberg-Marquadt é baseado no método de otimização de Newton para sistemas não-lineares. Na prática, o método de otimização de Newton para treinamento não é utilizado diretamente em função da grande complexidade, do elevado tempo computacional, ou mesmo impossibilidade da estimação das derivadas de segunda ordem. O método de Newton atualiza os pesos segundo a Equação 2.10, sendo a correção ótima para os pesos considerando a aproximação de segunda ordem (BARBOSA; FREITAS; NEVES, 2005):

$$W(n+1) = W(n) - H^{-1}(n) \cdot g_n \quad (2.10)$$

onde g_n é definido pela Equação 2.11:

$$g_n = 2J^T(W)\Delta e(W) \quad (2.11)$$

Na definição do método de Newton, tem-se H como sendo a matriz quadrada de derivadas parciais de segunda ordem do erro quadrático de aproximação em relação aos pesos. Esta matriz é usualmente denominada de Hessiana e é definida pela Equação 2.12.

$$H = \frac{\partial^2 E_R(W)}{\partial W^2} \quad (2.12)$$

onde E_R (erro quadrático médio) e $e(W)$, são definidos pelas equações 2.13 e 2.14:

$$E_R = \frac{1}{n} \sum_{i=1}^n (y_i - y_{ei})^2 \quad (2.13)$$

$$e(W) = \sum_{i=1}^n (y_i - y_{ei}) \quad (2.14)$$

onde y_i é a saída fornecida pela rede neural e y_{ei} é o valor real correspondente à saída da rede. O algoritmo de Levenberg-Marquadt é uma aproximação ao método de Newton, sendo uma técnica de otimização mais eficiente que a do gradiente descendente. Com este

algoritmo, se faz uma aproximação da matriz Hessiana usando a matriz Jacobiana, de acordo com a equação 2.15:

$$H(n) = J^T(n)J(n) \quad (2.15)$$

onde J é a matriz Jacobiana, que é o vetor de derivadas parciais do erro em relação aos pesos para o i -ésimo padrão e n -ésima iteração (considerando que a atualização dos pesos é realizada em cada época) (HAYKIN, 2001). A matriz Jacobiana é definida pela Equação 2.16:

$$J(n) = \frac{\partial e(W)}{\partial W} \quad (2.16)$$

onde J é a Jacobiana.

A regra de atualização de pesos do Levenberg-Marquardt é (HAGAN; MENHAJ, 1994):

$$W(n+1) = W(n) - \left(J^t(n) J(n) + \mu I \right)^{-1} J^T(n) e(W) \quad (2.17)$$

Na Equação 2.18, J é a matriz jacobiana das derivadas dos erros relacionados aos pesos, μ é um valor escalar e $e(W)$ é um vetor de erros. Se o valor de μ é grande, a expressão acima representa uma descida mais rápida (com passo $1/\mu$), enquanto que, para pequenos valores de μ , a expressão é reduzida para o método de Gauss Newton, que é mais rápido e mais preciso, próximo do erro mínimo. O valor de μ pode aumentar ou diminuir em função da performance ou desempenho.

2.4 Transformadas de Imagens

Uma imagem pode ser definida como uma função bidimensional, $f(x, y)$, onde x e y são as coordenadas espaciais e a amplitude f de um par de coordenadas x e y é chamada de intensidade ou nível de cinza naquele ponto. Como qualquer função, uma imagem pode admitir transformações matemáticas que enfatizam determinados aspectos, como por exemplo, sua representação no domínio da frequência (GONZALEZ; WOODS; EDDINS, 2008).

2.4.1 Transformada Discreta do Cosseno (DCT – Discrete Cosine Transform)

A Transformada Discreta do Cosseno (DCT – Discrete Cosine Transform) é uma técnica que converte um sinal (1D ou 2D) em componentes de frequências elementares. Com a aplicação da DCT, grande parte da energia dos dados é armazenada em poucos

coeficientes. Entre as principais aplicações da transformada discreta do cosseno pode-se mencionar: codificação e filtragem de imagens, reconhecimento de padrões e extração de características (KHAYAM, 2003).

Devido às características de representação no domínio da frequência e compactação da informação mais representativa (baixa frequência) em poucos coeficientes, a variação de apenas um coeficiente do domínio DCT pode implicar em mudança em todos os pixels da mesma imagem no domínio do espaço. Portanto, esta característica da transformada DCT pode ser útil para representar crescimento/decrescimento de regiões e deslocamentos na forma de variações nos coeficientes do domínio DCT, sendo uma solução para o problema da restrição à vizinhança de pixels no domínio do espaço.

A definição da DCT bidimensional de uma imagem de entrada em uma imagem B de saída é um processo bem conhecido na literatura, definido, entre outros autores por (GONZALEZ; WOODS; EDDINS, 2008).

A definição da Transformada DCT bidimensional é dada pela seguinte fórmula:

$$C(u, v) = \alpha(u)\alpha(v) \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} f(x, y) \cos\left(\frac{\pi(2x+1)u}{2M}\right) \cos\left(\frac{\pi(2y+1)v}{2N}\right), \quad (2.18)$$

$$0 \leq u \leq M - 1$$

$$0 \leq v \leq N - 1$$

A Transformada Inversa é obtida através da seguinte fórmula:

$$f(x, y) = \sum_{u=0}^{M-1} \sum_{v=0}^{N-1} \alpha(u)\alpha(v)C(u, v) \cos\left(\frac{\pi(2x+1)u}{2M}\right) \cos\left(\frac{\pi(2y+1)v}{2N}\right), \quad (2.19)$$

$$0 \leq u \leq M - 1$$

$$0 \leq v \leq N - 1$$

onde:

- $f(x, y)$ é a imagem no domínio do espaço,
- $C(u, v)$ é a imagem no domínio da transformada DCT,
- M é o número de linhas de A ,
- N é o número de colunas de A ,

•

$$\alpha(u) = \begin{cases} \sqrt{\frac{1}{M}} & \text{para } u = 0 \\ \sqrt{\frac{2}{M}} & \text{para } 1 \leq u \leq M - 1 \end{cases} \quad (2.20)$$

•

$$\alpha(v) = \begin{cases} \sqrt{\frac{1}{N}} & \text{para } v = 0 \\ \sqrt{\frac{2}{N}} & \text{para } 1 \leq v \leq N - 1 \end{cases} \quad (2.21)$$

2.4.2 Wavelets

A palavra wavelet é devido a Morlet e a Grossman no começo dos anos 80 (1980). Usaram a palavra francesa *ondelette*, significando “a onda pequena” (*small wave*). Um pouco depois foi transformada no inglês traduzindo “onda” em “*wave*”, dando o wavelet. A transformada Wavelet é classificada amplamente em: Transformada Wavelet Discreta (DWT - Discrete Wavelet Transform) e Transformada Wavelet Contínua (CWT - *Continuous Wavelet Transform*). A diferença principal entre os dois é que a CWT opera sobre cada possível escala e frequência e a DWT usa um subconjunto específico de todos os valores da escala e da frequência.

Wavelets são nada mais que ondas pequenas com determinadas propriedades que as tornam adequadas a servirem de base para decomposição de outras funções, assim como senos e cossenos servem de base para decomposições de Fourier. Wavelets permitem fazer análise em tempo-frequência, ou espaço-frequência, para imagens. Assim, é teoricamente possível construir um sistema para separar os instrumentos e codificar seus padrões em coeficientes wavelets diferentes (as técnicas de Fourier permitem separar os conteúdos espectrais, mas mostram-se pobres em descrever ao mesmo tempo as condições temporais, padrões não estacionários).

A transformada wavelet é uma ferramenta que fatia dados ou funções ou operadores em componentes frequenciais diferentes, e então estuda cada componente com uma resolução casada com sua escala (DAUBECHIES; MALLAT; WILLSKY, 1992).

Originalmente empregadas para análise de sinais sísmicos na geofísica (MORLET, 1983), as transformadas wavelet foram melhor e mais amplamente formalizadas com os esforços dos matemáticos, embora tais ideias já constituíssem um centro de convergência dos desenvolvimentos de físicos, matemáticos, engenheiros, entre outros. Com isso, o uso das técnicas de wavelet na área de análise de dados vem crescendo exponencialmente, pois ela representa uma síntese de ideias antigas aliada a resultados matemáticos recentes, a eficientes algoritmos computacionais e ao interesse de ampla comunidade (DAUBECHIES; MALLAT; WILLSKY, 1992).

A idéia fundamental da Transformada de Wavelet é que ela é uma transformada pontual e proporcional à escala. Ela analisa o sinal em escalas diferentes e se desloca analisando cada trecho do sinal. O parâmetro de translação se relaciona com a localização da “janela”. Analisa-se o sinal aos poucos. Este termo corresponde à informação de tempo no domínio da transformada. Processa-se essencialmente o conteúdo que estiver dentro da janela. Wavelets são funções que satisfazem uma relação de escala e translação, sendo capazes de gerar uma base ortonormal para o espaço $L^2(R)$. Uma função será chamada de uma função wavelet se, além de ser integrável, ela satisfizer a seguinte relação de escala e translação: $\Psi_{ij}(x) = 2^{-\frac{j}{2}} \Psi(2^{-j}x - k)$. A função Ψ é chamada wavelet mãe, as demais

wavelets Ψ_{ij} são geradas por mudanças de escala e translações (j, k respectivamente). As wavelets são utilizadas na análise wavelet, onde se utiliza a chamada transformada wavelet.

Um ponto importante na análise wavelet é que as funções de base são funções que decaem a zero quando $x \rightarrow \infty$, isso faz com que a contribuição de cada elemento da base seja local, ao contrário do que ocorre na análise de Fourier, na qual as funções de base (seno e cosseno) são não nulas em todo domínio $(-\infty, \infty)$ e, portanto possuem contribuição global. Mas, por outro lado, as wavelets não são tão bem localizadas no domínio da frequência como as funções da base de Fourier (Princípio da incerteza de Heisenberg). A análise wavelet traz consigo uma análise em resoluções múltiplas, onde o nível de resolução é dado pelo índice j . Nesta análise em resoluções múltiplas, geramos uma sequência de subespaços encaixantes, onde as funções de base numa escala j_0 não “enxergam” detalhes de tamanho menor que 2^{-j_0} .

A transformada wavelet é uma transformada linear que pode ser utilizada na análise de sinais não estacionários para extrair informações das variações em frequência desses sinais e para detectar suas estruturas temporalmente e/ou espacialmente localizadas.

A Transformada Contínua Wavelet é definida pela Equação 2.22:

$$W(a, b) = \int_{-\infty}^{\infty} f(x)\Psi_{a,b}(x)dx \quad (2.22)$$

A transformada inversa é dada pela Equação 2.23:

$$f(x) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} W(a, b)\Psi_{a,b}(x)dadb \quad (2.23)$$

Nas Equações 2.22 e 2.23, a é o parâmetro de escala, b é o parâmetro de translação e $\Psi_{a,b}$ é conhecido como Wavelet Mãe.

Para aplicações práticas é preferível, por razões de eficiência, funções diferenciáveis com um suporte compacto como as Wavelets Mães. Contudo, para satisfazer requerimentos analíticos (na TW contínua) e por razões teóricas deve-se escolher uma wavelet mãe no subespaço do espaço $L^1(\mathbb{R}) \cap L^2(\mathbb{R})$. Este é o espaço das funções mensuráveis que são ambas absolutamente quadraticamente integráveis:

$$\int_{-\infty}^{\infty} |\Psi(x)| dx < \infty \quad (2.24)$$

e

$$\int_{-\infty}^{\infty} |\Psi(x)|^2 dx < \infty \quad (2.25)$$

Formalmente, para que uma função seja denominada de wavelet, usualmente denotada pela letra Ψ , ela deve satisfazer as propriedades a seguir:

1. A integral dessa função wavelet deve ser zero:

$$\int_{-\infty}^{\infty} \Psi(x) dx = 0 \quad (2.26)$$

Isso garante que a função wavelet tenha uma forma do tipo onda. Essa condição é conhecida como condição de admissibilidade.

2. A função wavelet deve ter energia unitária:

$$\int_{-\infty}^{\infty} |\Psi(x)|^2 dx = 1 \quad (2.27)$$

Isso garante que a função wavelet possua suporte compacto, ou com um decaimento rápido de amplitude, garantindo a localização espacial. Para Ψ ser a uma wavelet para a CWT (transformada wavelet contínua), a wavelet mãe deve satisfazer alguns critérios para que possa estabelecer uma transformada inversa.

Para a DWT (transformada wavelet discreta), apenas precisa-se de que a série wavelet esteja no espaço de $L^2(\mathbb{R})$. A maioria das construções da transformada discreta usa o método de multiresolução que define a wavelet pela função de escala. Na maioria das situações é adequado restringir Ψ uma função contínua com um número M mais alto de momentos desconhecidos, isto é, $m < M$.

$$\int_{-\infty}^{\infty} x^m \Psi(x) dx = 0 \quad (2.28)$$

De modo geral, as funções wavelet possuem a propriedade de dupla localização: em frequência e em tempo, com um compromisso entre elas. A localização temporal ocorre por ser a função wavelet localizada em um intervalo finito. Dessa forma, à medida que a escala aumenta, as funções wavelet dessas escalas ficam localizadas em intervalos de comprimento cada vez menores. Em cada nível de escala, todas as funções wavelet possuem a mesma forma, só mudando seus pontos de localização, i.e., transladando. A localização em frequência deve-se à transformada de Fourier da função wavelet poder ser interpretada como um filtro passa-banda. Devido à propriedade de dupla localização das funções wavelet, a transformada wavelet é dita do tipo local em tempo-frequência, com resolução temporal e em frequência inversamente proporcionais.

2.4.3 Transformada Wavelet Discreta – DWT

A Transformada Wavelet Contínua é obtida fazendo-se translações e escalonamentos contínuos da wavelet-mãe sobre o sinal, obtendo-se a correlação entre esses sinais. A saída é uma função bidimensional (imagem) de tempo vs escala. Ou seja, para o sinal de entrada, tem-se uma representação de coeficientes em 2D, onde a wavelet-mãe é infinitamente transladada e escalonada na forma de uma representação contínua da decomposição do

sinal. Esta decomposição, por ter infinitos deslocamentos e translações, e ainda gerar muita redundância, é ineficiente em tempo e recursos computacionais.

A Transformada Wavelet Discreta (DWT – *Discrete Wavelet Transform*) é interessante por ser uma adaptação da transformada contínua que contorna os problemas de redundância e eficiência computacional. A discretização ocorre apenas no domínio dos parâmetros de escala e translação, e não no tempo ou espaço. Tem-se, portanto, a escolha de somente um sub-conjunto de escalas e deslocamentos específicos, de onde os coeficientes são calculados, ou seja, ocorre uma discretização da transformada contínua. Os valores de a e b discretizados são dados pelas Equações 2.29 e 2.30. De acordo com Daubechies (1992), a discretização dos parâmetros a e b resulta na Equação 2.31:

$$a = a_0^m \quad (2.29)$$

$$b = nb_0a_0^m \quad (2.30)$$

$$W(m, n) = \frac{1}{\sqrt{a_0^m}} \sum_{k=-\infty}^{\infty} f(k) \Psi\left(\frac{k - nb_0a_0^m}{a_0^m}\right) \quad (2.31)$$

Os termos a_0 e b_0 são denominados, respectivamente, como passos de escala e translação, sendo valores básicos para a variação de a e b . As variáveis m e n pertencem ao conjunto dos inteiros positivos e são parâmetros discretos.

O esquema de discretização mais utilizado na literatura foi criado por Mallat (1989) e opera com escalas e translações baseadas em potências de 2, onde o sinal é decomposto hierarquicamente por um banco de filtros. O componente de baixa frequência, que é resultado do filtro passabaixas, é conhecido como “aproximação”. Já o componente de alta frequência, que é resultado do filtro passa-altas, é conhecido como “detalhe”. O algoritmo de Mallat (1989) atribui os valores $a_0 = 2$ e $b_0 = 1$, resultando na Equação 2.32

$$W(m, n) = 2^{\frac{m}{2}} \sum_{k=-\infty}^{\infty} f(k) \Psi(2^m k - n) \quad (2.32)$$

Na prática, a decomposição de um sinal discreto em sinais de frequências complementares pode ser obtida pela operação matemática de convolução. Considerando-se um sinal discreto $x[n]$, a filtragem corresponde a convolução deste sinal com a função de resposta ao impulso $h[n]$ do filtro (SHENG, 1996). A convolução é obtida pela Equação 2.33.

$$y[n] = x[n] * h[n] = \sum_{k=-\infty}^{\infty} x[k] \cdot h[n - k] \quad (2.33)$$

Com a filtragem por filtros passa-alta e passa-baixa, verifica-se que a quantidade de amostras resultantes dos dois filtros é igual ao dobro do número de amostras do sinal original. Como houve duplicação no número de amostras, a frequência do sinal filtrado poderá ser a metade da frequência do sinal original para que o mesmo ainda atenda ao teorema de Nyquist. Portanto, é possível excluir metade das amostras do sinal filtrado sem que haja perda de informação. Tal procedimento é chamado de downsampling, ou subamostragem e é descrito pela Equação 2.35

$$a[n] = \sum_{-\infty}^{\infty} x[k] \cdot g[2m - k] \quad (2.34)$$

$$d[n] = \sum_{-\infty}^{\infty} x[k] \cdot h[2m - k] \quad (2.35)$$

onde $a[n]$ são os coeficientes de aproximação, que resultam do filtro passa-baixas g e $d[n]$ são os coeficientes de detalhe, que resultam do filtro passa-altas h . O processo de decomposição pelo banco de filtros pode ser mais facilmente entendido por meio de um diagrama de blocos, onde o sinal S é decomposto em coeficientes de aproximação (a) e detalhes (d) e, nos níveis a seguir, o coeficiente de aproximação é recursivamente decomposto em componentes de aproximação e detalhes, formando uma árvore de decomposição. A cada nível, os filtros têm como resposta um coeficiente com metade da banda de frequência do sinal de entrada.

2.4.4 Transformada Wavelet Bidimensional

Mallat (1989) também definiu a DWT para imagens. Neste contexto, o conceito de DWT foi adaptado para decompor imagens em componentes de diferentes frequências espaciais. Nas imagens, os atributos de baixa frequência concentram mais informações geométricas de objetos e fluidos. Já os componentes de alta frequência contêm mais informação de borda, textura e ruídos.

As imagens são analisadas da seguinte forma: A DWT divide a imagem em componentes de alta escala e baixa escala. Da mesma forma como são decompostos os sinais, nas imagens ocorre da mesma forma. Os componentes de baixa frequência são chamados de “aproximações” e os componentes de alta frequência são chamados de “detalhes”. No caso da DWT bidimensional, são obtidos quatro conjuntos de coeficientes: CA (Coeficiente de aproximação), CH (Coeficiente de detalhes horizontais), CV (coeficiente de detalhes verticais) and CD (coeficiente de detalhes diagonais) para cada nível.

3 Trabalhos Relacionados

Grande parte das pesquisas tratam de técnicas de processamento de imagens que buscam constatar e quantificar as previsões feitas por métodos estatísticos. Como a de [Mukhopadhyay et al. \(2011\)](#) propõe um modelo de predição de uma série temporal de imagens meteorológicas com base em redes neurais MLP (*Multilayer Perceptron*) aplicada a um conjunto de pixels (janela de vizinhança) das imagens, resultando em um pixel de tempo futuro.

Outro trabalho, como o de [Sousa \(2012\)](#), utilizou uma sequência de imagens de sensoriamento remoto NDVI (*Normalized Difference Vegetation Index*), observando e quantificando as variáveis com a finalidade de fazer a regressão para gerar estimativas que extrapolassem a série. Utilizando o Erro MAE para comparar a imagem original e a prevista.

[Bandeira \(2012\)](#) aplicou dois métodos de predição de séries temporais de sinais sísmicos de jazidas baseados em regressão linear e polinomial, obtendo uma imagem extrapolada da série.

[Lazzarotto et al. \(2015\)](#) propõem uma metodologia na qual é feita uma avaliação do desempenho por meio da previsão de séries temporais das leituras de um instrumento da barragem da usina hidrelétrica de Itaipu usando uma combinação híbrida dos previsores ARIMA-GARCH e redes neurais artificiais, com a utilização da decomposição wavelet.

4 Estratégias Propostas

Séries temporais podem ser definidas como um conjunto de observações geradas sequencialmente no tempo. O processo de predição das séries temporais consiste em, através das observações de eventos passados, gerar estimativas de eventos futuros. Estimar eventos futuros geralmente é um trabalho de baixa precisão, pois o processo pode envolver atributos que ocorrem aleatoriamente, tais como ruído de aquisição de dados e ainda outros eventos que podem ocorrer num intervalo mais curto que a amostragem da série. A predição, também conhecida como previsão, de dados futuros em séries temporais tem sido de grande importância em diversas áreas. Alguns exemplos de aplicações são:

- previsão do tempo, utilizando imagens de satélites;
- previsão de oscilações no valor das ações da bolsa de valores;
- previsão da disponibilidade de recursos naturais;
- previsão da oscilação no valor de um determinado produto;
- previsão de movimento de fluidos no subsolo;

Existem diversos métodos para auxiliar na tarefa de predição de séries temporais, como por exemplo: modelos de Suavização Exponencial, modelos auto-regressivos (AR), de médias móveis (MA) e Modelos ARIMA. Tecnologias de inteligência computacional, tais como redes neurais, lógica nebulosa e algoritmos genéticos, proporcionam a criação de metodologias avançadas de predição (RIBEIRO; GOLDSCHMIDT; CHOREN,). Segundo Morettin e Tolo (2006) a maioria dos métodos de predição de séries temporais baseia-se na idéia de que o comportamento futuro depende de seu comportamento passado. Os métodos de predição utilizados na prática podem variar muito, desde modelos simples e intuitivos até modelos mais complexos.

Neste capítulo, são propostas diversas estratégias de predição de séries temporais de imagens. São feitas previsões usando Árvore de Decisão e são comparados com as previsões da Rede Neural. Os métodos propostos de predição da série temporal são divididos nas seguintes categorias:

- Predição com árvore de decisão
 - No domínio do espaço
 - No domínio DCT
 - No domínio híbrido Wavelet e DCT

- Previsão com rede neural

No domínio do espaço

No domínio DCT

No domínio híbrido Wavelet e DCT

A seguir, são propostos dois métodos de previsão que podem ser aplicados ao domínio do espaço e também às imagens transformadas.

4.0.1 Predição de Pixel

A predição de pixel é feita tratando-se cada pixel das imagens da série temporal como sendo uma função em 1D dos níveis de cinza, de forma que a variação na intensidade do pixel seja aproximada para esta função, como mostra a Figura 9.

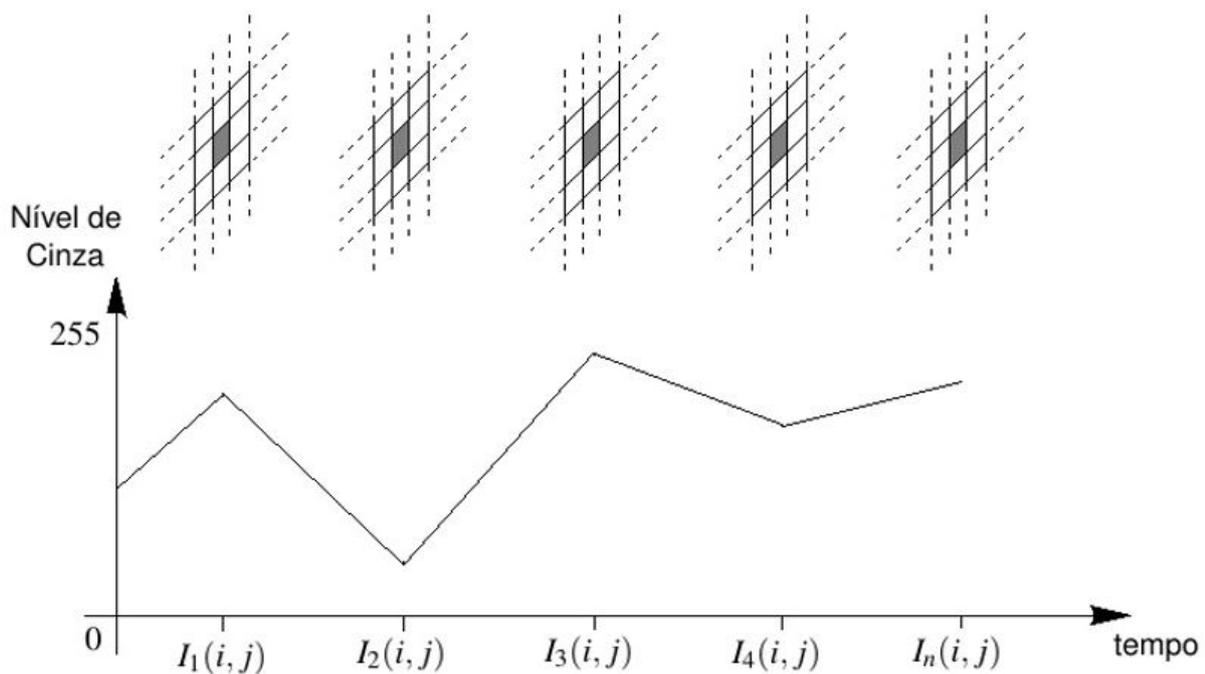


Figura 9 – Série temporal representada por variação nos níveis de cinza. Cada pixel da série corresponde ao mesmo local (i, j) , formando uma função unidimensional.

4.0.2 Predição no Domínio do Espaço

Este é o método direto de predição, sem nenhuma transformação matemática. A árvore tem como entrada os pixels das imagens da série temporal, $I_1(i, j)$ a $I_n(i, j)$, resultando numa saída (pixel) de tempo futuro $I_{n+1}(i, j)$. O mesmo processo é repetido para cada pixel das imagens.

4.0.3 Predição no Domínio da Transformada DCT

Esta estratégia é semelhante à estratégia do domínio do espaço, porém, ao invés de extrapolar um pixel na série temporal, é extrapolido um coeficiente no domínio DCT. Para isso, foi aplicada a transformada DCT sobre todas as imagens. A seguir, a árvore foi gerada como os pixels $I_{1...n}(i, j)$ (coeficiente do domínio DCT), extrapolando o pixel de tempo futuro $I_{n+1}(i, j)$ (coeficiente no domínio DCT). Depois é feita a transformada inversa da imagem extrapolada.

Com o método de predição no domínio DCT, espera-se obter uma predição que não seja restrita a apenas um pixel no domínio do espaço. Com isso, o método de extrapolação não fica restrito às posições locais dos pixels nas imagens, mas sim a alterações globais associadas a esses coeficientes. Além disso, verifica-se uma forte compactação da imagem, reduzindo-se as redundâncias e concentrando a maior parte das informações em poucos coeficientes.

4.0.4 Predição no Domínio Híbrido Wavelet e DCT

O problema geral quando se faz predição de séries temporais é que não existe um único modelo que seja eficaz em todos os tipos de séries temporais (FILHO, 2006). Com esta estratégia de predição, objetiva-se encontrar os melhores resultados para a predição da série temporal pela combinação de diferentes modelos e não pela seleção do melhor modelo individual. Portanto, em previsões de séries temporais, este modelo com árvore de decisão e transformada híbrida deve ter uma solução melhorada, caso esta seja aplicada ao mesmo problema sob diferentes perspectivas.

Segundo Lira (2004), uma das vantagens da análise com wavelet em relação à análise de Fourier é a existência de um maior grau de liberdade na escolha dos sinais básicos da decomposição. Em geral, a extração de uma dada característica do sinal é melhor executada com uma certa família de wavelets. Contudo, não existem critérios definitivos a respeito da escolha de uma “base de wavelets” mais adequada para um dado sinal. Muito embora já se encontrem disponíveis um grande número de famílias, surgem frequentemente novas wavelets, possibilitando novas aplicações. Elas podem ser potencialmente atrativas na representação de sinais com certas simetrias.

Com a transformada wavelet, pode-se também decompor a imagem em componentes de diferentes resoluções e frequências. Assim, a árvore pode ser gerada com a mesma imagem processada por diferentes filtros. Além disso, verifica-se também que o uso de diferentes wavelet-mãe pode resultar em diferentes padrões de correlação entre cada wavelet-mãe em cada decomposição da imagem, o que implica em uma análise sob diferentes perspectivas, podendo-se atenuar os erros de predição com a combinação de diferentes configurações de wavelets.

5 Materiais e Métodos

5.1 Ferramentas Computacionais

Este trabalho foi desenvolvido com o apoio dos seguintes softwares:

- Matlab ([MATLAB, 2013](#))
- Gimp ([GIMP, 2016](#))
- Proeikon ([KIM, 2012](#))

O Matlab é um software amplamente utilizado para pesquisa, desenvolvimento e análise envolvendo métodos computacionais em diversas áreas, como por exemplo, otimização, redes neurais, processamento de sinais, processamento de imagens, entre outras.

Neste trabalho, o Matlab foi utilizado na implementação árvore de decisão e da rede neural, da transformada Wavelet e da transformada DCT aplicados às imagens sintéticas e sísmicas. O Gimp (*GNU Image Manipulation Program*) é um software de edição de imagens. Esta ferramenta foi usada na criação das imagens sintéticas, utilizando métodos de criação de figuras geométricas. O Proeikon é um pacote de softwares e bibliotecas de processamento de imagens e vídeo. Estas ferramentas foram utilizadas no cálculo do erro MAE aplicado às imagens previstas.

5.2 Dados Utilizados

5.2.1 Imagens Sintéticas

Este trabalho utiliza uma metodologia que possibilite a predição de variação dos níveis de cinza, deslocamentos, crescimento e decréscimo de regiões em séries temporais de imagens. Portanto, é interessante que esses algoritmos sejam testados com imagens sintéticas de simples visualização e validação. Para isso, foi criada uma série temporal de 15 imagens de 150x150 pixels com figuras geométricas e as seguintes transições: crescimento, decréscimo, deslocamento e variação nos níveis de cinza, todos simultaneamente na mesma série temporal, como mostra a Figura 10.

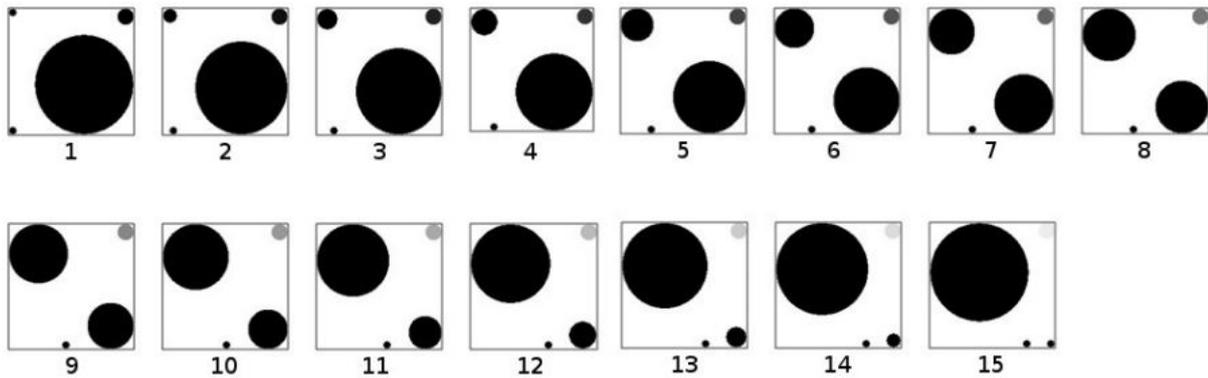


Figura 10 – Série temporal de imagens sintéticas com as seguintes figuras geométricas: Uma bola crescente no canto superior esquerdo; uma bola com variação nos níveis de cinza no canto superior direito; uma bola decrescente no canto inferior direito; uma bola deslizante no canto inferior esquerdo.

Na série temporal de imagens sintéticas, todas as transições foram criadas da seguinte forma:

- Variando-se raio das circunferência e deslocamento em 8 pixels, nas circunferências do canto superior esquerdo (crescente); do canto inferior direito (decrescimento) e do canto inferior esquerdo (deslocamento).
- Variando-se o nível de cinza de 0 a 238 (15 níveis de cinza) na circunferência do canto superior direito.

5.2.2 Imagens de Sensoriamento Remoto

O principal objetivo deste trabalho é a predição de imagens de sensoriamento da NASA, cedidas pelo *Center for Space Research University of Texas*, dos satélites Terra e Aqua de uma área que inclui o Texas e regiões envolventes. As imagens possuem dimensões de 5493 x 5340 pixels e uma codificação de 8 bits. Os dados começaram a ser capturados a partir de 2001 para o satélite Terra e de 2002 para os dados do Aqua.

O intervalo de tempo entre cada cena é de 16 dias. O intervalo de tempo entre cada cena, se utilizando dados de ambos os sensores, Terra e do Aqua, é de 8 dias. Os valores de NDVI (*Normalized Difference Vegetation Index*) são calculados para pixels com um tamanho de 250 metros. Os níveis de cinza são maiores onde a vegetação possui boa saúde e cobre a maior parte da superfície da terra. Os níveis de cinza mais baixos representam desertos ou onde a seca ou o frio reduziu a vegetação. A série temporal é apresentada na Figura 11.

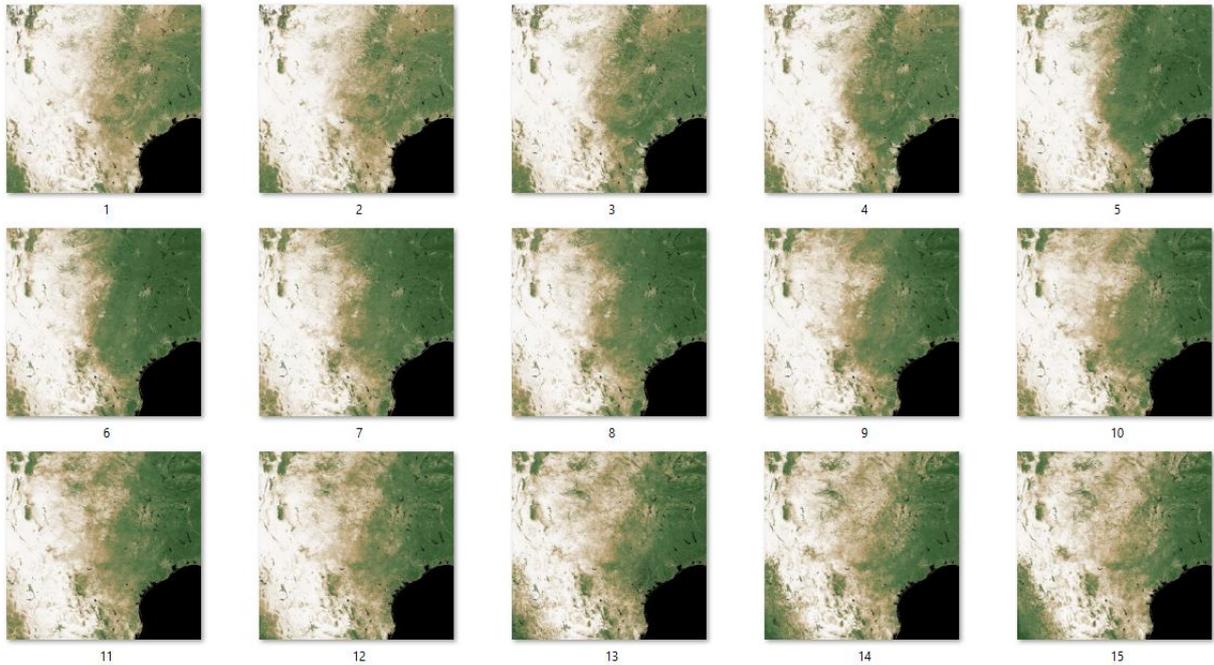


Figura 11 – Série temporal de imagens da área do Texas e regiões envolvidas.

Devido as dimensões das imagens, foi escolhida uma área que apresentava variação nos recursos hídricos para ser recortada e processada posteriormente. Foi escolhida a cidade de Fort Smith que é cortada pelo rio Arkansas River, como possível observar na Figura 12. A série temporal é apresentada na Figura 13.

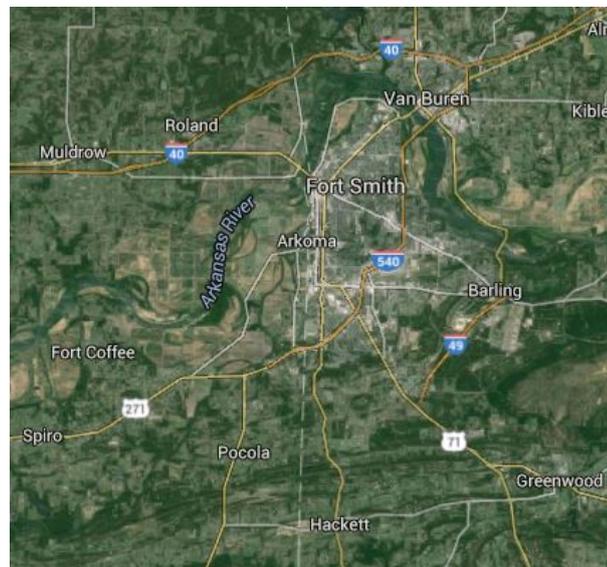


Figura 12 – Imagem do Google da região da Cidade de Fort Smith e do Rio Arkansas River.

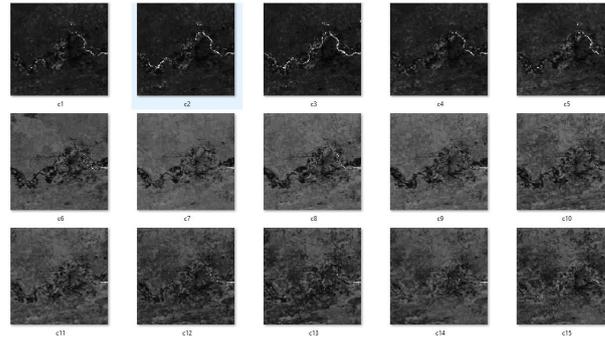


Figura 13 – Série temporal de imagens recortada do Rio Arkansas River.

5.2.3 Metodologia Proposta

Dispõe-se de duas séries temporais de imagens, sendo 15 imagens sintéticas e 15 imagens de sensoriamento remoto. A partir dessas séries, foi feita a predição da seguinte forma:

- Predição da 13^a imagem, usando as primeiras 12 imagens para gerar a árvore de decisão.
- Predição da 14^a imagem, usando as primeiras 13 imagens para gerar a árvore de decisão.
- Predição da 15^a imagem, usando as primeiras 14 imagens para gerar a árvore de decisão.

Também são aplicadas metodologias de predição de séries temporais de imagens já mencionadas. Os algoritmos são aplicadas as imagens sintéticas e as imagens de sensoriamento remoto, conforme a seguinte classificação:

- No domínio do espaço
- No domínio DCT
- No domínio híbrido Wavelet e DCT

5.2.4 Metodologia de Validação

O método utilizado para validação foi o MAE (*Mean Absolute Error*). O erro MAE é uma grandeza estatística usada para medir a proximidade entre o resultado predito e o resultado real. Quanto mais próximo o valor do MAE de zero, mais eficaz é o método de predição.

Na equação a seguir, x_i corresponde ao valor real, y_i corresponde ao valor predito e N é o número de replicações.

$$MAE = \frac{1}{N} \sum_{i=1}^N |x_i - y_i| \quad (5.1)$$

6 Resultados e Discussão

Este trabalho propôs o uso de técnicas de predição de séries temporais de imagens com base em árvores de decisão, onde objetivou-se contemplar duas situações distintas: imagens sintéticas de figuras geométricas e sem ruído e imagens de sensoriamento remoto relativa a recursos hídricos, que não possuem formato definido.

6.0.1 Resultados com Imagens Sintéticas

As seguintes figuras mostram as imagens resultantes de cada estratégia de predição da séries sintética. Nas imagens, a grande área em verde e magenta representam a diferença entre as previstas e as originais. As previsões feitas com a rede neural, demonstra que a predição no domínio com a rede neural no espaço não detecta crescimento/decrescimento e deslocamento de regiões. Já as previsões feitas com a árvore de decisão apresentam melhores resultados na detecção do crescimento/decrescimento de áreas.

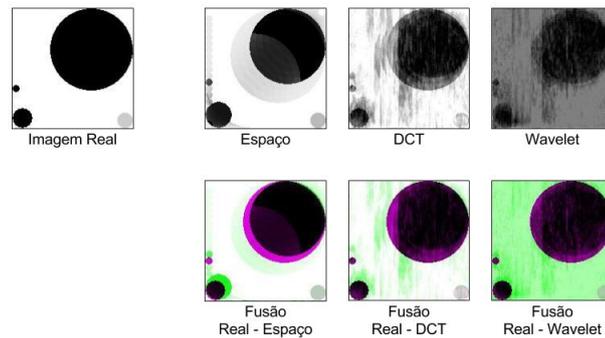


Figura 14 – Imagens resultantes da predição de pixel feita pela árvore de decisão da 13^a sequência. As simulações do domínio wavelet/DCT foram feitas no nível de resolução 1. A fusão da imagem real com as imagens preditas destaca as diferenças nas cores verde e magenta.

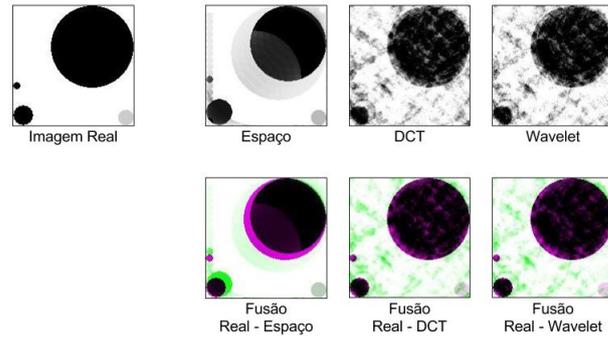


Figura 15 – Imagens resultantes da predição de pixel feita pela rede neural da 13^a sequência. As simulações do domínio wavelet/DCT foram feitas no nível de resolução 1. A fusão da imagem real com as imagens preditas destaca as diferenças nas cores verde e magenta.

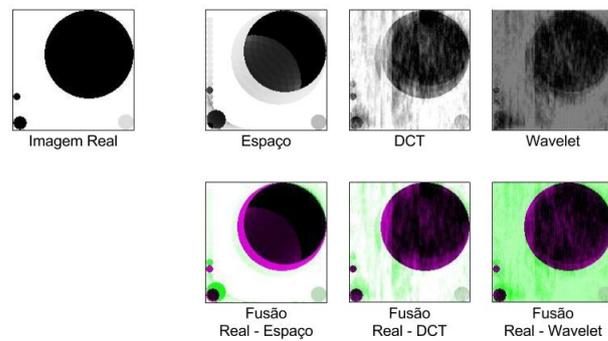


Figura 16 – Imagens resultantes da predição de pixel feita pela árvore de decisão da 14^a sequência. As simulações do domínio wavelet/DCT foram feitas no nível de resolução 1. A fusão da imagem real com as imagens preditas destaca as diferenças nas cores verde e magenta.

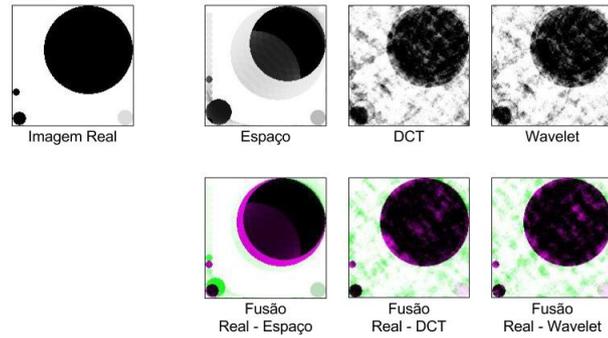


Figura 17 – Imagens resultantes da predição de pixel feita pela rede neural da 14^a sequência. As simulações do domínio wavelet/DCT foram feitas no nível de resolução 1. A fusão da imagem real com as imagens previstas destaca as diferenças nas cores verde e magenta.

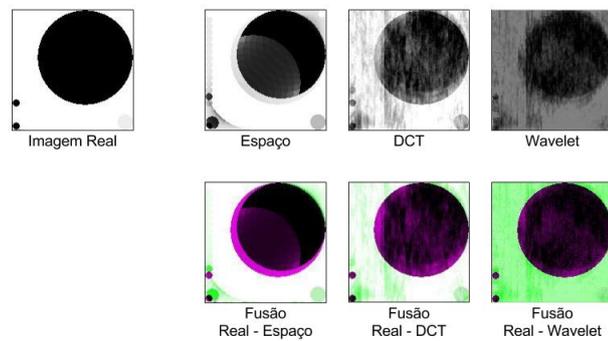


Figura 18 – Imagens resultantes da predição de pixel feita pela árvore de decisão da 15^a sequência. As simulações do domínio wavelet/DCT foram feitas no nível de resolução 1. A fusão da imagem real com as imagens previstas destaca as diferenças nas cores verde e magenta.

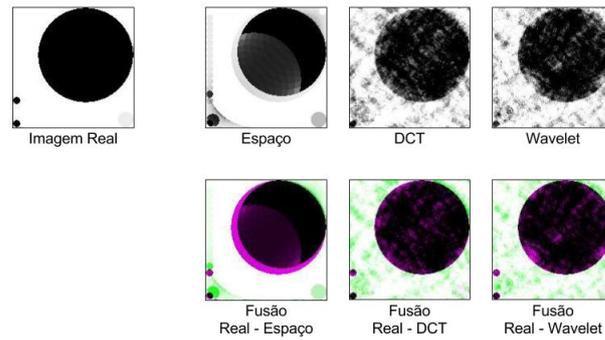


Figura 19 – Imagens resultantes da predição de pixel feita pela rede neural da 15^a sequência. As simulações do domínio wavelet/DCT foram feitas no nível de resolução 1. A fusão da imagem real com as imagens previstas destaca as diferenças nas cores verde e magenta.

As tabelas a seguir avaliam as predições, por meio do erros MAE, dados em porcentagem, das previsões das imagens 13, 14 e 15. Cada previsão foi feita no domínio do espaço e nos domínios da frequência.

Tabela 1 – Erro MAE da predição de pixel das imagens 13, 14 e 15 com a Árvore de Decisão.

Predição do Pixel com Árvore de Decisão			
Imagem	MAE (%) da DCT	MAE (%) do Espaço	MAE (%) do Wavelet/DCT
Imagem Prevista 13	11.87	12.06	38.45
Imagem Prevista 14	11.14	11.63	36.87
Imagem Prevista 15	11.94	10.96	34.22

Tabela 2 – Erro MAE da predição de pixel das imagens 13, 14 e 15 com a Rede Neural.

Predição do Pixel com Rede Neural			
Imagem	MAE (%) da DCT	MAE (%) do Espaço	MAE (%) do Wavelet/DCT
Imagem Prevista 13	12.52	14.28	11.69
Imagem Prevista 14	14.50	12.15	12.07
Imagem Prevista 15	16.20	12.44	12.19

6.0.2 Resultados com Imagens de Sensoriamento Remoto

As imagens que seguem mostram as previsões feitas por cada estratégia de predição aplicadas às sequências 11, 12, 13, 14 e 15 das imagens de sensoriamento remoto. É apresentada da seguinte forma: imagem original no canto esquerdo superior, imagens previstas pela rede neural na linha superior a direita e imagens previstas pela árvore de decisão na linha inferior a direita.

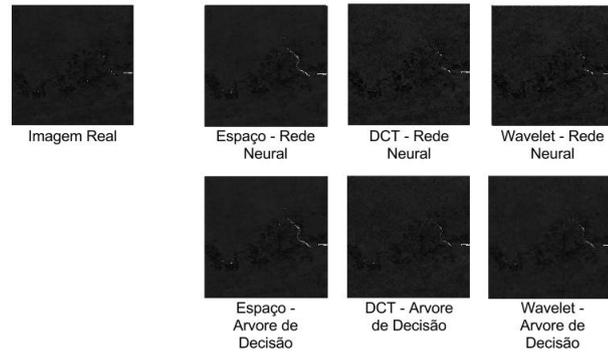


Figura 20 – Imagens resultantes da predição de pixel feita pela rede neural e pela arvore de decisão da 11^a sequência. As simulações do domínio wavelet/DCT foram feitas no nível de resolução 1.

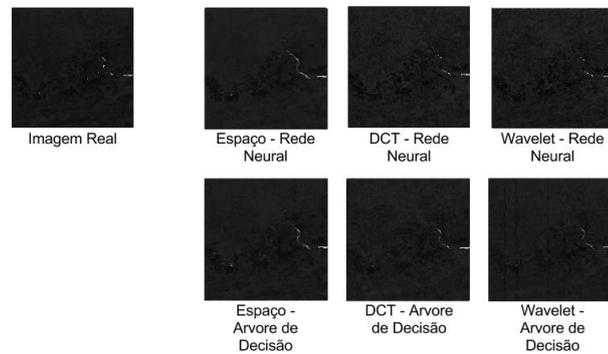


Figura 21 – Imagens resultantes da predição de pixel feita pela rede neural e pela arvore de decisão da 12^a sequência. As simulações do domínio wavelet/DCT foram feitas no nível de resolução 1.

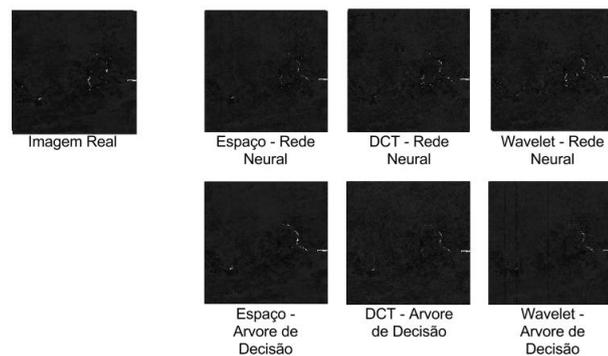


Figura 22 – Imagens resultantes da predição de pixel feita pela rede neural e pela arvore de decisão da 13^a sequência. As simulações do domínio wavelet/DCT foram feitas no nível de resolução 1.

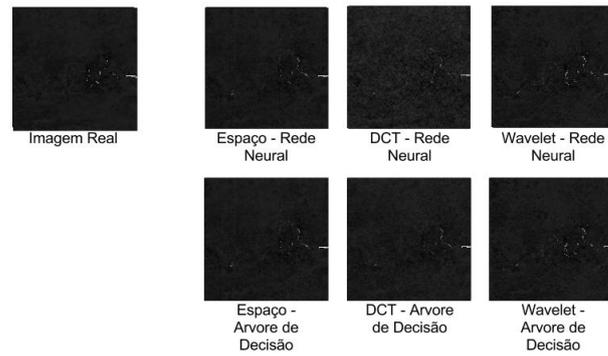


Figura 23 – Imagens resultantes da predição de pixel feita pela rede neural e pela arvore de decisão da 14^a sequência. As simulações do domínio wavelet/DCT foram feitas no nível de resolução 1.

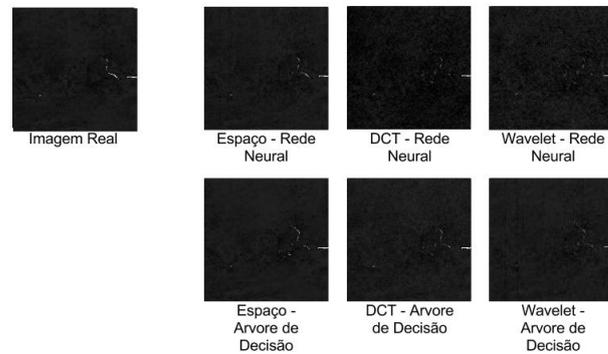


Figura 24 – Imagens resultantes da predição de pixel feita pela rede neural e pela arvore de decisão da 15^a sequência. As simulações do domínio wavelet/DCT foram feitas no nível de resolução 1.

As tabelas a seguir mostram o desempenho da árvore de decisão e da rede neural com as diferentes estratégias, por meio do cálculo de erro MAE.

Tabela 3 – Erros MAE % das predições de pixel feitas com a rede neural.

Imagem	Predição do Pixel com Rede Neural		
	MAE (%) da DCT	MAE (%) do Espaço	MAE (%) do Wavelet/DCT
Imagem Prevista 11	4.73	3.89	4.67
Imagem Prevista 12	5.00	4.27	4.94
Imagem Prevista 13	4.64	4.29	4.77
Imagem Prevista 14	4.21	4.23	4.63
Imagem Prevista 15	4.17	4.10	4.42

Tabela 4 – Erros MAE % das predições de pixel feitas com a árvore de decisão.

Imagem	Predição do Pixel com Árvore de Decisão		
	MAE (%) da DCT	MAE (%) do Espaço	MAE (%) do Wavelet/DCT
Imagem Prevista 11	1.67	1.39	1.68
Imagem Prevista 12	2.07	1.77	1.49
Imagem Prevista 13	2.07	1.61	2.34
Imagem Prevista 14	2.29	1.31	1.79
Imagem Prevista 15	4.17	1.26	1.86

6.0.3 Considerações Sobre os Resultados

O uso de árvores de decisão, se mostrou interessante para predição de séries temporais apresentando um menor erro MAE. A árvore de decisão também apresentou menor tempo para realizar a previsão.

A árvore apresentou diferentes resultados com diferentes estratégias em diferentes situações. Na predição com as imagens sintéticas a árvore se mostrou mais precisa na variação do nível de cinza. Em compensação ela apresenta resultados inferiores para estimativa de crescimento/deslocamento de regiões, como é possível observar nas imagens sintéticas.

A predição no domínio DCT e no híbrido DCT/wavelet apresentam melhores resultados na estimativa de crescimento/decrescimento e na estimativa de deslocamento. O método híbrido apresentou alto ruído de fundo nas previsões da árvore de decisão, gerando um erro MAE maior, o que não acontece nas predições feitas pela rede neural.

Nas predições das imagens de sensoriamento remoto visando os recursos hídricos, feitas pela árvore de decisão, se mostram mais precisas tanto visualmente como através do erro MAE. No domínio da frequência também apresenta melhores resultados que a rede neural, mas apresentando mais ruídos.

7 Conclusões

O presente trabalho teve como objetivo propor novos métodos de previsão de séries temporais, utilizando árvores de decisão e transformadas do domínio da frequência. Para as previsões foram utilizadas imagens de sensoriamento remoto, as quais apresentam recursos hídricos, a fim de obter informações futuras sobre esses recursos. Essas informações são de vital importância para melhor direcionar os recursos para a prevenção ou a mitigação dos efeitos causados pela falta de água.

A idéia por trás deste trabalho foi utilizar novos métodos de regressão que apresentassem melhores resultados que os métodos atualmente utilizados, como por exemplo a rede neural. A predição pode auxiliar de forma inteligente nas tomadas de decisões que possam prevenir ou mitigar a falta de recursos hídricos.

Para validar estas abordagens com a árvore de decisão, usou-se também uma série temporal de imagens sintéticas de fácil visualização, permitindo que seja possível fazer uma validação visual de crescimento/descrescimento de regiões, deslocamento e alterações nos tons de cinza. A previsão no domínio da frequência apresentaram mais ruído que as imagens previstas no domínio do espaço.

Os resultados obtidos com a árvore de decisão se mostraram promissores na predição de séries temporais de imagens. A árvore de decisão necessitou de menos tempo para realizar as previsões, também apresentando um menor erro MAE.

7.0.1 Perspectivas Futuras

Este trabalho também abre novas perspectivas sobre predição de séries temporais de imagens. A árvore de decisão combinada com os métodos de conversão de dados também é admissível em séries temporais de outras áreas, por exemplo, séries temporais climáticas. Principalmente dados referentes ao estados do Rio Grande do Norte, buscando realizar cooperação com grupos que atuam na área de ciências ambientais.

O processo desenvolvido também rendeu uma futura patent aberta em conjunto com os orientadores e a UERN.

Outra perspectiva futura seria a implementação de uma máquina de comitê com a árvore de decisão e a rede neural. Como o próprio nome indica, comitê de máquina é a agregação de mais de uma máquina de aprendizado na produção de uma única solução computacional para um determinado problema. O uso do comitê de máquina seria motivado pela busca de previsões mais precisas.

Referências

- ARAÚJO, L. E. d. S. *CRISE HÍDRICA E POTENCIAL ENERGÉTICO DA REGIÃO SUDESTE*. Tese (Doutorado) — Universidade Federal do Rio de Janeiro, 2016. Citado na página 15.
- ASSÍS, J. C. d. Água sob medida. *Agroanalysis*, v. 18, p. 83–88, 1998. Citado na página 15.
- BANDEIRA, C. L. L. *Estimativa do Movimento de Fluidos em um Reservatório Petrolífero Usando Métodos de Previsão de Séries Temporais Baseados em Co-Registro de Imagens*. Dissertação (Mestrado) — Universidade Federal Rural do Semi-Árido – UFERSA; Universidade do Estado do Rio Grande do Norte – UERN, 2012. Citado na página 41.
- BARBOSA, A. H.; FREITAS, M. S. d. R.; NEVES, F. d. A. d. Confiabilidade estrutural utilizando o método de monte carlo e redes neurais. *Rem: Revista Escola de Minas, SciELO Brasil*, v. 58, n. 3, p. 247–255, 2005. Citado na página 33.
- BARRETT, E. C. *Introduction to environmental remote sensing*. [S.l.]: Routledge, 2013. Citado na página 17.
- BRAGA, A. de P.; FERREIRA, A. C. P. de L.; LUDERMIR, T. B. *Redes neurais artificiais: teoria e aplicações*. [S.l.]: LTC Editora, 2007. Citado 3 vezes nas páginas 27, 31 e 32.
- CAMARA, G.; DAVIS, C.; MONTEIRO, A. *Introdução a Ciência da Geoinformação*. [S.l.: s.n.], 2001. Citado na página 22.
- CYBENKO, G. Approximation by superpositions of a sigmoidal function. *Mathematics of control, signals and systems*, Springer, v. 2, n. 4, p. 303–314, 1989. Citado na página 31.
- DAUBECHIES, I.; MALLAT, S.; WILLSKY, A. S. *Special issue on wavelet transforms and multiresolution signal analysis-introduction*. [S.l.]: IEEE-INST ELECTRICAL ELECTRONICS ENGINEERS INC 345 E 47TH ST, NEW YORK, NY 10017-2394, 1992. Citado na página 36.
- FILHO, M. de A. L. Previsão de carga de curto prazo usando ensembles de previsores selecionados e evoluidos por algoritmos geneticos. Biblioteca Digital da Unicamp, 2006. Citado na página 45.
- GIMP. Gimp: Gnu image manipulation program. *Version*, v. 2, p. 12, 2016. Citado na página 47.
- GONZALEZ, R. C.; WOODS, R. E.; EDDINS, S. Morphological image processing. *Digital Image Processing. Volume*, v. 3, p. 627–688, 2008. Citado 2 vezes nas páginas 34 e 35.
- HAGAN, M. T.; MENHAJ, M. B. Training feedforward networks with the marquardt algorithm. *Neural Networks, IEEE Transactions on, IEEE*, v. 5, n. 6, p. 989–993, 1994. Citado na página 34.

- HAYKIN, S. *Neural networks: A comprehensive foundation*. [S.l.]: Prentice Hall International, 2001. Citado 7 vezes nas páginas 11, 27, 28, 29, 30, 31 e 34.
- KHAYAM, S. A. The discrete cosine transform (dct): theory and application. *Michigan State University*, v. 114, 2003. Citado na página 35.
- KIM, H. Proeikon-rotinas e programas em c++ para processamento de imagens e visão computacional. *São Paulo*, 2012. Citado na página 47.
- KUMAR, D. A.; ALI, H. A.; HAMMED, S. Detecting diseased images by segmentation and classification based on semi-supervised learning. *12th International Conference on Hybrid Intelligent Systems (HIS)*, 2012. Citado 3 vezes nas páginas 11, 19 e 20.
- LAZZAROTTO, E.; GRAMANI, L. M.; NETO, A. C.; JUNIOR, L. A. T.; FRANCO, E. M. C. Melhoria na previsão da série temporal de instrumentos de monitoramento de barragem via combinação de métodos. *Cadernos do IME-Série Estatística*, v. 38, p. 1, 2015. Citado na página 41.
- LIRA, M. M. d. S. Wavelets na compactação e processamento de sinais de distúrbios em sistemas de potência para classificação via redes neurais artificiais. Universidade Federal de Pernambuco, 2004. Citado na página 45.
- MALLAT, S. G. A theory for multiresolution signal decomposition: the wavelet representation. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, Ieee, v. 11, n. 7, p. 674–693, 1989. Citado 2 vezes nas páginas 39 e 40.
- MATLAB. Natick. *Massachusetts: The MathWorks Inc*, 2013. Citado na página 47.
- MCCULLOCH, W. S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. *The bulletin of mathematical biophysics*, Springer, v. 5, n. 4, p. 115–133, 1943. Citado na página 27.
- MENESES, P.; SANO, E.; ASSAD, E. *Introdução ao processamento de imagens digitais de satélites de sensoriamento remoto*. [S.l.]: Editora Universidade de Brasília, 1991. Citado 2 vezes nas páginas 17 e 20.
- MMA. Conhecendo o pan – brasil: Programa de ação nacional de combate à desertificação e mitigação dos efeitos da seca/secretaria de recursos hídricos, coordenação técnica de combate à desertificação. 2006. Citado na página 15.
- MOREIRA, M. *Fundamentos do sensoriamento remoto e metodologias de aplicação*. [S.l.]: Universidade Federal de Viçosa, 2005. Citado 3 vezes nas páginas 17, 21 e 22.
- MORETTIN, P. A.; TOLOI, C. *Análise de séries temporais*. [S.l.]: Blucher, 2006. Citado na página 43.
- MORLET, J. Sampling theory and wave propagation. In: *Issues in Acoustic Signal—Image Processing and Recognition*. [S.l.]: Springer, 1983. p. 233–261. Citado na página 36.
- MUKHOPADHYAY, A.; SHUKLA, B. P.; MUKHERJEE, D.; CHANDA, B. A novel neural network based meteorological image prediction from a given sequence of images. In: *IEEE. Emerging Applications of Information Technology (EAIT), 2011 Second International Conference on*. [S.l.], 2011. p. 202–205. Citado na página 41.

- QUINLAN, J. R. Combining instance-based and model-based learning. In: *Proceedings of the Tenth International Conference on Machine Learning*. [S.l.: s.n.], 1993. p. 236–243. Citado 2 vezes nas páginas 23 e 26.
- QUINLAN, J. R. *C4. 5: programs for machine learning*. [S.l.]: Elsevier, 2014. Citado na página 24.
- RIBEIRO, C. V.; GOLDSCHMIDT, R. R.; CHOREN, R. Ime. Citado na página 43.
- ROSENBLATT, F. The perceptron: a probabilistic model for information storage and organization in the brain. *Psychological review*, American Psychological Association, v. 65, n. 6, p. 386, 1958. Citado na página 31.
- RUSSEL, S.; NORWING, P. Artificial intelligence a modern approach second edition—upper saddle river. *NS: Prentice Hall/2003.–1988 c*, 2003. Citado na página 23.
- SHENG, Y. Wavelet transform. *The transforms and applications handbook*, Boca Raton, Fl: CRC, v. 747, p. 827, 1996. Citado na página 39.
- SOMLYÓDY, L.; VARIS, O. Freshwater under pressure. *International Review for Environmental Strategies*, v. 6, n. 2, p. 181–204, 2006. Citado na página 15.
- SOUSA, W. R. N. e. a. Monitoring of desertification process through trend estimates of time series. *GEOBIA. Rio de Janeiro: [s.n.]*, . p. 561-565, 2012. Citado na página 41.
- SPERLING, E. Considerações sobre a saúde de ambientes aquáticos. *Bio*, v. 2, n. 3, p. 53–6, 1993. Citado na página 15.
- TRABALHO, G. de. Índices de avaliação de projetos hídricos.(gtz). *Coletânea de textos traduzidos: índices hidro-ambientais 3/4 análise e avaliação do seu uso na estimação dos impactos ambientais e projetos hídricos*, 1995. Citado na página 15.
- TUNDISI, J. G.; BARBOSA, F. Conservação e uso sustentável de recursos hídricos. *Ângulos da água: desafios da integração*. Belo Horizonte: editora uFMG, p. 157–83, 2008. Citado na página 15.
- ZUBEN, F.; ATTUX, R. *Computação Evolutiva. Material Complementar da disciplina IA013–Introdução à Computação Natural*. [S.l.]: Universidade de Campinas– UNICAMP. October, 2008. Citado 2 vezes nas páginas 25 e 26.