



**Fundação Educacional do Município de Assis
Instituto Municipal de Ensino Superior de Assis
Campus "José Santilli Sobrinho"**

PEDRO HENRIQUE RAVAGNANI PINTAR

**UM ESTUDO EXPLORATÓRIO SOBRE REDES NEURAIS ARTIFICIAIS
COM ÊNFASE NA REDE DE HOPFIELD**

**Assis/SP
2018**



**Fundação Educacional do Município de Assis
Instituto Municipal de Ensino Superior de Assis
Campus "José Santilli Sobrinho"**

PEDRO HENRIQUE RAVAGNANI PINTAR

**UM ESTUDO EXPLORATÓRIO SOBRE REDES NEURAIS ARTIFICIAIS
COM ÊNFASE NA REDE DE HOPFIELD**

Projeto de pesquisa apresentado ao curso de Ciência da Computação do Instituto Municipal de Ensino Superior de Assis – IMESA e a Fundação Educacional do Município de Assis – FEMA, como requisito parcial à obtenção do Certificado de Conclusão.

Orientando(a): Pedro Henrique Ravagnani Pintar
Orientador(a): Prof. Dr. Alex S R S Poletto

**Assis/SP
2018**

FICHA CATALOGRÁFICA

PINTAR, Pedro

Um estudo exploratório sobre redes neurais artificiais com ênfase na rede de Hopfield/ Pedro Henrique Ravagnani Pintar. Fundação Educacional do Município de Assis – FEMA – Assis, 2018.

45p.

Orientador: Prof. Dr. Alex S R S Poletto

Trabalho de Conclusão de Curso – Instituto Municipal de Ensino Superior de Assis – IMESA.

1. Rede Neural Artificial. 2. Rede de Hopfield. 3. Inteligência Artificial

CDD: 001.6
Biblioteca da FEMA

UM ESTUDO EXPLORATÓRIO SOBRE REDES NEURAIS ARTIFICIAIS COM ÊNFASE NA REDE DE HOPFIELD

PEDRO HENRIQUE RAVAGNANI PINTAR

Trabalho de Conclusão de Curso apresentado ao Instituto Municipal de Ensino Superior de Assis, como requisito do Curso de Graduação, avaliado pela seguinte comissão examinadora:

Orientador: _____
Prof. Dr. Alex S R S Poletto

Examinador: _____
Profa. Me. Diomara Martins Reigato Barros

RESUMO

Inteligência artificial e redes neurais artificiais são duas tecnologias emergentes, juntas estas buscam ao máximo prover a aproximação de simular o mesmo esquema dos neurônios biológicos, criando assim sistemas computacionais capazes de adquirir conhecimento e realizar tomadas de decisões a partir da experimentação. As Redes Neurais Artificiais (RNA's) provem diversos benefícios no âmbito tecnológico bem como a solução para problemáticas. A fim da validação dessa tecnologia com ênfase na solução proposta pela Rede de Hopfield, esse projeto conduziu uma ampla pesquisa na área de redes neurais artificiais e inteligência artificial. Dessa forma apresentando as diversas vantagens e possíveis melhorias que a tecnologia apresenta para auxiliar no reconhecimento de padrões, viabilizando a proposta da Rede de Hopfield no âmbito de sistemas computacionais inteligentes.

Palavras-chave: Rede Neural Artificial, Inteligência Artificial, Rede de Hopfield, Sistemas Computacionais Inteligentes.

ABSTRACT

Artificial intelligence and artificial neural networks are two emerging technologies. Together, they seek the closest approach to simulate the same scheme of biological neurons, thus creating computational systems capable of acquiring knowledge and to make decisions based on the experimentation. Artificial Neural Networks (ANN's) provide several benefits in the technological scope as well as the solution to problems. In order to validate this technology with emphasis on the solution proposed by the Hopfield Network, this project conducted a wide research in the area of artificial neural networks and artificial intelligence. Thus presenting the various advantages and possible improvements that the technology presents to help in the recognition of standards, making feasible the proposal of the Hopfield Network in the scope of intelligent computational systems.

Keywords: Artificial Neural Network, Artificial Intelligence, Hopfield Network, Intelligent Computational Systems.

LISTA DE ILUSTRAÇÕES

Figura 1: A célula nervosa (neurônio biológico)	18
Figura 2: Expressão matemática que define o processo recepção de	19
Figura 3: Expressão matemática que define a tomada de decisão	19
Figura 4: A estrutura do neurônio artificial de McCulloch e Pitts	20
Figura 5: Modelos de Redes (Quantidade de Camadas)	22
Figura 6: Grafo arquitetural de uma rede de Hopfield consistindo de	27
Figura 7: Representação de estado de mistura triplo.....	28
Figura 8: Representação do número 6 na forma de memórias	29
Figura 9: Representação de estado de mistura triplo.....	30
Figura 10: Representação de estado espúrio de vidro de spin	30
Figura 11: Algoritmo que define a estrutura da rede	34
Figura 12: Algoritmo para inicialização e restauração do padrão	35
Figura 13: Algoritmo para calcular pesos sinápticos	35
Figura 14: Entrada de dados com ruídos	37
Figura 15: Saída de dados após treinamento e interação	37
Figura 16: Imagem utilizada para o treinamento da rede utilizando píxels ...	38
Figura 17: Imagem de entrada utilizada para o treinamento da rede e	39
Figura 18: Saída de imagem após 30 iterações	39
Figura 19: Saída de imagem após 120 iterações	39
Figura 20: Imagem natural utilizada de entrada	40
Figura 21: Imagem natural de saída após diversas alterações	40

SUMÁRIO

1. INTRODUÇÃO	10
1.1 OBJETIVOS	10
1.2 JUSTIFICATIVAS	11
1.3 MOTIVAÇÃO	11
1.4 PERSPECTIVAS DE CONTRIBUIÇÃO	11
1.5 METODOLOGIA DE PESQUISA	12
1.6 ESTRUTURA DO TRABALHO	12
2. REDES NEURAIS ARTIFICIAIS	14
2.1 INTRODUÇÃO.....	14
2.2 HISTÓRICO.....	15
2.3 REDE NEURAL BIOLÓGICA.....	17
2.4 MODELO MCP	18
2.5 ARQUITETURAS DAS REDES NEURAIS ARTIFICIAIS.	20
2.6 APRENDIZADO.....	23
3. REDE HOPFIELD.....	26
3.1 MEMÓRIA ASSOCIATIVA.....	26
3.2 MODELO DE HOPFIELD	27
3.3 FASES DE OPERAÇÃO DA REDE DE HOPFIELD.....	28
3.4 ARMAZENAMENTO.....	29
3.5 ESTADOS ESPÚRIOS	30
4. PROPOSTA DE TRABALHO.....	32
4.1 DESCRIÇÃO DE PROPOSTA.....	32
4.2 TECNOLOGIAS UTILIZADAS	32
4.3 METODOLOGIA DE ANÁLISE	33
5. DESENVOLVIMENTO DO TRABALHO.....	34
5.1 ALGORITMO DE SIMULAÇÃO	34

5.2 RECONHECIMENTO DE PADRÕES	37
5.2 APLICAÇÕES.....	40
6. CONCLUSÃO	42
6.1 RESULTADOS ALCANÇADOS	42
6.2 PROJEÇÕES FUTURAS.....	43
REFERÊNCIAS.....	44

1. INTRODUÇÃO

Ao decorrer dos anos diversos avanços tecnológicos ocorreram no âmbito de desenvolvimento de sistemas inteligentes, algumas tecnologias, como as redes neurais artificiais (RNA's), tentam simular as redes neurais biológicas a fim de garantir soluções para determinadas problemáticas.

Muito diferente dos computadores, o cérebro mamífero pode apresentar bilhões de neurônios para a realização de tomadas de decisões inteligentes, por contrapartida, uma rede neural artificial dificilmente apresentará mais do que milhares de unidades de processamentos simples com muitas interconexões.

O presente trabalho tem por objetivo apresentar as tecnologias e estudos que são base para o desenvolvimento de um algoritmo de simulação do sistema neural biológico, com o intuito de identificar padrões e classifica-los, além de apresentar um estudo sobre o modelo de Hopfield e a validação do mesmo.

A presente monografia será apresentada da seguinte maneira. No segundo capítulo será apresentado as redes neurais artificiais, seu histórico, características, modelo computacional e como a rede é capaz de adquirir conhecimento. No terceiro capítulo é realizada a apresentação do modelo proposto por Hopfield, onde será discutida as características do modelo. No quarto capítulo serão apresentados modelos de algoritmos e um estudo sobre os mesmos a fim de consolidar as pesquisas em prol da criação de uma RNA. O quinto capítulo apresentará como a RNA solucionará as problemáticas de reconhecimento de padrões, destacando suas características e apresentando soluções encontradas atualmente. Por fim, no capítulo final é feita a conclusão de estudo, apresentando os resultados alcançados pela pesquisa.

1.1 OBJETIVOS

O objetivo geral deste projeto de pesquisa é o de fomentar conhecimento a respeito de redes neurais artificiais com ênfase no modelo de Hopfield para a criação de uma rede

neural artificial capaz de solucionar a problemática de identificação de padrões, contribuindo para a validação da solutiva de Hopfield e demonstrar que seu modelo pode apresentar resultado condizentes com o proposto.

Como resultado desta pesquisa, espera-se que uma solução seja encontrada através da experimentação do modelo, acrescentando informações a fim de garantir a viabilidade do estudo de redes neurais artificiais em prol do desenvolvimento científico.

1.2 JUSTIFICATIVAS

Existem diversas discussões sobre a capacidade de a inteligência artificial ser válida para a geração de artefatos computacionais com características próximas ou idênticas a de um ser inteligente. Alguns problemas complexos, atualmente intratáveis com as técnicas de programação tradicionais são solucionados por redes neurais artificiais. A razão para tal, pode estar na sua capacidade de aprender e na sua estrutura paralela. (Haykin, 2001).

1.3 MOTIVAÇÃO

A motivação para a escolha dessa temática dá-se pelo fato da tecnologia de inteligência artificial e redes neurais artificiais estar crescente no mercado atualmente, isso ocorre devido ao fato desta conter habilidades e possibilidades atraentes para representação do conhecimento, raciocínio e aprendizado, sendo que a proposta da usabilidade da mesma auxilia na obtenção de melhores resultados na solução de problemas específicos como análise de imagem, detecção de padrões, entre outros.

1.4 PERSPECTIVAS DE CONTRIBUIÇÃO

Ao concluir esta pesquisa, espera-se que o estudo da validação da rede de Hopfield fomenta outras pesquisas com base em redes neurais artificiais, devido ao fato de redes neurais artificiais serem uma tecnologia emergente, além de, compartilhar e disseminar o

resultado das pesquisas realizadas e as conclusões alcançadas em sua finalização, com o intuito de auxiliar o desenvolvimento da comunidade científica e evolução tecnológica.

1.5 METODOLOGIA DE PESQUISA

Para atingir os objetivos propostos nesta pesquisa, uma metodologia foi definida com base na revisão da literatura de diversos trabalhos a respeito da rede de Hopfield a fim de identificar e validar a solução proposta. A pesquisa será conduzida de forma a fazer um levantamento bibliográfico de artefatos que tenham em sua composição um estudo da rede de Hopfield, com o intuito de obter um acréscimo de informações e dados que permitam uma análise do método proposto, bem como a aplicação deste para a solução de problemas específicos.

1.6 ESTRUTURA DO TRABALHO

A estrutura deste trabalho será composta das seguintes partes:

- **Capítulo 1 – Introdução:** Neste capítulo é realizada a contextualização da área de estudo, apresentação dos objetivos, justificativas, motivação, perspectivas de contribuição e metodologia de pesquisa para o desenvolvimento desta obra.
- **Capítulo 2 – Redes Neurais Artificiais:** Neste capítulo é apresentado um breve histórico dessa tecnologia, principais características de uma rede neural biológica que uma rede neural artificial tende a simular, o modelo MCP, a arquitetura de uma rede neural artificial, como é realizado o aprendizado de uma rede neural artificial e as diversas aplicações da mesma.
- **Capítulo 3 – Rede Hopfield:** Neste capítulo é apresentado um dos principais modelos de redes neurais artificiais, sua contribuição científica, principais características e finalidades, bem como a metodologia de armazenamento e funcionamento.
- **Capítulo 4 – Proposta de Trabalho:** Neste capítulo é definido as ferramentas utilizadas e a problemática que servirá de arcabouço para a análise da solução proposta bem como a metodologia de análise.

- **Capítulo 5 – Desenvolvimento do Trabalho:** Neste capítulo, é apresentada a implementação do algoritmo da abordagem proposta, bem como os experimentos e resultados da utilização do modelo estudado, analisados nos contextos atuais.
- **Capítulo 6 – Conclusão:** Neste capítulo, são revisitados e discutidos as vantagens, desvantagens e resultados obtidos da implementação e análise das soluções com embasamento no modelo de Hopfield.
- **Referências**

2. REDES NEURAIS ARTIFICIAIS

Este capítulo tem por objetivo, apresentar a definição de uma rede neural artificial, bem como, suas vantagens e benefícios proporcionados pelo seu uso. As RNA's consistem em uma tecnologia que tenta simular as redes neurais biológicas, contendo o propósito de resolver uma diversidade de problemas no âmbito de reconhecimento de padrões, predição, memória associativa, otimização e controle.

2.1 INTRODUÇÃO

É de fácil percepção que o cérebro humano é superior a um computador digital. Podemos utilizar para exemplo o processamento de informação visual, uma vez que desde de nossa infância é possível com que realizemos o reconhecimento de objetos e face, muito mais rápido e ágil do que um sistema de inteligência artificial que está operando em um computador muito potente.

A capacidade humana possui características que são muito almeçadas em sistemas artificiais, o que justifica o estudo de computação neural, mesmo que uma grande RNA tenha um limitador devido a quantidade de unidades de processamento em comparação aos bilhões de neurônios presentes na rede neural biológica.

O que mais se destaca no administrador de redes é a capacidade de aprendizado que registra, graças a seu cérebro, as informações relativas ao que já aconteceu para criar novas técnicas e aprimorar outras existentes. Esta característica de aprendizado é encontrada nas Redes Neurais que possuem a habilidade de tolerar entradas ruidosas e simular um aprendizado (RUSSEL, 2004)

As RNA's são técnicas computacionais que apresentam um modelo matemático inspirado na estrutura neural de organismos inteligentes. Estas redes adquirem conhecimento através da experiência e podem ser utilizadas na resolução de uma grande classe de problemas encontrados em várias áreas aplicadas: classificação, identificação, diagnóstico, análise de sinais e de imagens, otimização e controle. (Silva, 2003)

Em comparativo ao sistema biológico, uma RNA possui unidades de processamento, unidades essas que correspondem aos neurônios. Dessa forma as unidades são interconectadas entre si, possuindo pesos, que são valores numéricos, que por sua vez representam as sinapses. Essa conexão faz-se necessário pois tem o propósito de determinar uma saída que servirá de entrada para outra unidade existente.

A variedade de modelos existentes em técnicas para modelos computacionais inteligentes se faz pela diversidade de definições do estado, forma de atualização dos neurônios e a topologia de rede.

A utilização e implementação de redes neurais têm-se mostrado fácil, e o emprego de uma rede neural pode variar de acordo com a habilidade de adaptação para a solução do problema proposto ou considerado, essa adaptação ocorre por meio da mudança nos pesos sinápticos (aprendizagem da rede neural), de modo a aperfeiçoar e melhorar sua eficiência.

Os estudos de redes neurais é um dos ramos que mais se desenvolve atualmente no âmbito de Inteligência Artificial.

2.2 HISTÓRICO

A ideologia de redes neurais artificiais originou-se através das ideias propostas na psicologia de Aristóteles e a base computacional no artigo de McCulloch e Pitts em 1943 (apud SILVA, 2003, p.5).

O artigo apresentado por McCulloch e Pitts descreveram um modelo do neurônio real que é utilizado na maioria dos modelos de RNA's atualmente e conhecido como MCP (apud SILVA, 2003, p.5).

Em 1949 surgiu a primeira teoria neurofisiológica para modificação de sinapses em neurônios reais (determinação do processo de aprendizagem do cérebro) por Donald Hebb. De acordo com sua teoria, "Se um neurônio A é repetidamente estimulado por um neurônio B, ao mesmo tempo em que ele está ativo, A ficará mais sensível aos estímulos de B, e a conexão sináptica de B para A será mais eficiente. Deste modo, B achará mais fácil estimular A para produzir uma saída". Esse procedimento de ajuste de pesos, frequentemente chamado de regra de Hebb, tem sido adotado de formas diferentes em

algoritmos de aprendizado para modelos de RNA's baseados no modelo MCP (SILVA, 2003).

Com um número suficiente dessas unidades simples (neurônios) e com conexões sinápticas ajustadas apropriadamente e operando de forma síncrona, McCulloch e Pitts mostraram que uma rede assim constituída realizaria, a princípio, a computação de qualquer função computável. Este era um resultado muito significativo e com ele é geralmente aceito o nascimento das disciplinas de Redes Neurais Artificiais e Inteligência Artificial (HAYKIN, 2001)

Em 1958, Frank Rosenblatt demonstrou com o seu novo modelo, o perceptron, que se fossem acrescentadas de sinapses ajustáveis, as RNA's com nodos MCP poderiam ser treinadas para classificar certos tipos de padrões. Rosenblatt descreveu uma topologia de RNAs, estruturada de ligação entre os nodos e, o mais importante, propôs um algoritmo para treinar a rede para executar determinados tipos de funções. O perceptron simples descrito por Rosenblatt possui três camadas: a primeira recebe as entradas do exterior e possui conexões fixas (retina); a segunda recebe impulsos da primeira através de conexões cuja eficiência de transmissão (peso) é ajustável e, por sua vez, envia para a terceira camada (resposta). Este tipo de perceptron comporta-se como um classificador de padrões, dividindo o espaço de entrada em regiões distintas para cada uma das classes existentes. O que Rosenblatt buscava era projetar RNA's que fossem capazes de fazer descobertas interessantes sem necessidade de regras (BRAGA, CARVALHO e LUDERMIR, 2000).

Também nos anos 60, Windrow e Hoff (VALLE FILHO, 2003) desenvolveram o conhecido ADALINE (ADAPtative LINear Element) e o MADALINE (Many ADALIDE) para o reconhecimento de padrões. O algoritmo de aprendizagem de Windrow é conhecido como Regra Delta (FERNANDES, 2003).

Marvin Minsky e Seymour Papert puderam demonstrar através do livro que publicaram em 1969, as limitações do perceptron de uma única camada, contrariando o conceito que havia sido defendido por Rosenblatt. O modelo até então apresentado era incapaz de resolver determinadas problemáticas não linearmente separáveis, como o "Ou Exclusivo".

Após o livro publicado por Marvin e Seymour Rosenblatt continuou seu estudo a fim de aperfeiçoar o Perceptrons. Entretanto, o déficit de algoritmos capazes de determinar os pesos sinápticos dificultava a implementação de alguns cálculos. Assis sendo, a

comunidade de ciência da computação deixou o paradigma de redes neurais por mais de duas décadas.

O renascimento dos interesses sobre as redes neurais artificiais aconteceu na década de 80, com diversos trabalhos, tais como o de Hopfield. Ele elaborou um algoritmo que estabiliza uma rede binária simétrica com realimentação (FERNANDES, 2003). Uma rede de Hopfield é capaz de estabilizar um conjunto de padrões de treinamento e também de realizar auto-associação semelhante a uma memória endereçada por conteúdo (FERNANDES, 2003).

A problemática encontrada na rede de perceptrons logo foram contrariadas pela generalização da Regra Delta, conhecida como algoritmo de Backpropagation, criado por Rumelhart, Hinton e Williams no ano de 1986. Dessa forma o interesse pela área voltou, sendo publicados novos modelos de Redes Neurais (Willshaw, Buneman e Longuet-Higgins, 1969; Anderson 1972; Kohonen, 1982; 1972; Fukushima 1975; Carpenter e Grossberg 1987^a; 1987^b; Kanerva, 1984) (SILVA, 2003).

2.3 REDE NEURAL BIOLÓGICA

O cérebro humano possui, pelo que se conhece, cerca de mais de 10 bilhões de neurônios. São eles as células mais diferenciadas do organismo, pois apresentam a maior complexidade estrutural e funcional. Durante o período da vida embrionária acontecem as divisões de células nervosas necessárias à vida humana e, graças a esse fato, nenhuma outra célula procriará após o nascimento do bebê, permanecendo, assim, seu número, igual para o resto de sua vida, sofrendo apenas alterações de volume e prolongamento de conexões com outras células (alguns pesquisadores contemporâneos têm defendido que neurônios podem ser reproduzidos) (TAFNER, XEREZ e RODRIGUES FILHO, 1995).

O neurônio consiste basicamente de corpo celular, axônio (e seus terminais) e dendritos. Os dendritos são os principais receptores de sinais neurais para a comunicação entre neurônios. O axônio é o canal pelo qual há a condução de mensagem para os terminais pré-sinápticos, onde cada neurônio está em contato sináptico com outros neurônios. O corpo celular é o local de processamento das informações recebidas pelos dendritos, no

qual um impulso nervoso no axônio é criado a partir de uma reação eletroquímica baseada em suas entradas (NOBACK, 2005).

O comportamento de uma sinapse química pode ser resumido da seguinte maneira: quando um potencial de ação chega a um terminal pré-sináptico, a despolarização da membrana pode fazer com que um pequeno número de vesículas sinápticas secrete, na fenda sináptica, um composto químico denominado neurotransmissor, que por sua vez, irá atuar nas proteínas receptoras do neurônio seguinte produzindo alterações na permeabilidade da membrana neural pós-sináptica, podendo excitá-lo, inibi-lo ou modificar de alguma forma sua intensidade (VILELA, 2018).

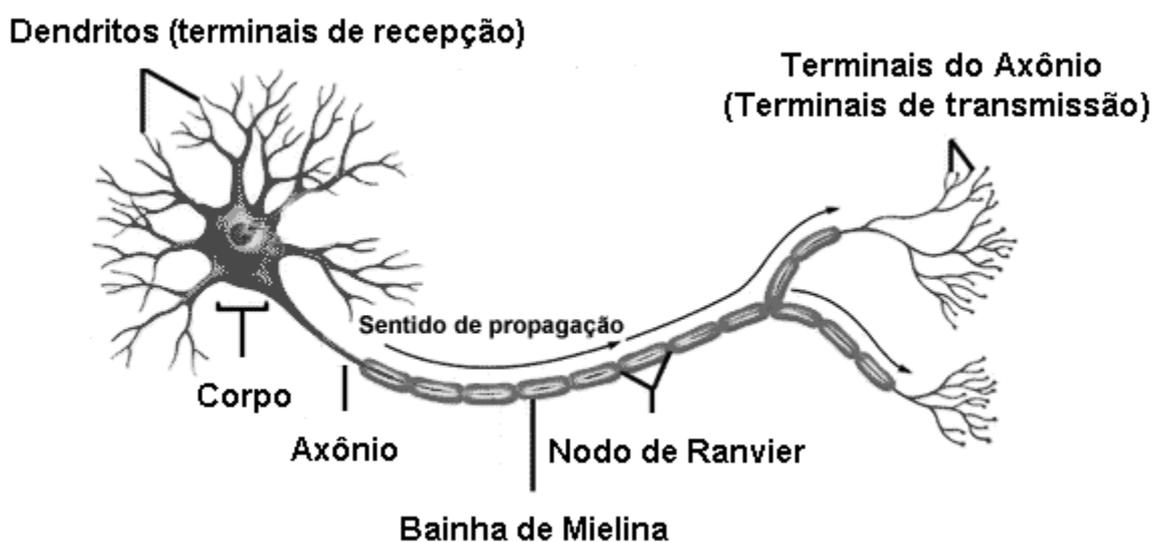


Figura 1: A célula nervosa (neurônio biológico)
Fonte: JUNIOR, 2011

2.4 MODELO MCP

Warren McCulloch e Walter Pitts – um neuroanatomista e um matemática, respectivamente – descreveram um modelo de cálculo lógico das redes neurais que unificava os estudos da neurofisiologia e da lógica matemática (HOPFIELD, 1984). O trabalho pioneiro deles deu início a era moderna das redes neurais, como produto eles criaram o então conhecido modelo McCulloch-Pitts, também conhecido como MCP.

Neste modelo, os dendritos do neurônio biológico k são representados pelas m entradas (x_i) e o axônio é representado pela saída (y_k). As sinapses nervosas são representadas por um peso (w_{ki}) associado a cada entrada, podendo este ser excitatório (valor positivo) ou inibitório (valor negativo). A saída do neurônio é o resultado da aplicação da função de ativação sobre a soma entre o somatório dos sinais de entradas ponderados pelos seus respectivos pesos sinápticos (w_k) e a polarização externa (bias) b_k que por sua vez tem o efeito de aumentar ou diminuir a polarização na função de ativação, assim $f()$ é a função de ativação do neurônio. O processo é descrito pelas seguintes equações (JUNIOR, 2011):

$$u_k = \sum_{i=1}^m x_i w_{ki}$$

Figura 2: Expressão matemática que define o processo recepção de informações.

$$y_k = f(u_k + b_k)$$

Figura 3: Expressão matemática que define a tomada de decisão.

McCulloch e Pitts simplificaram seu modelo assumindo que os nodos em cada camada da rede disparam sincronamente, isto é, todos os nodos são avaliados ao mesmo tempo e também que as entradas em um instante de tempo t produzem a sua saída no tempo $t+1$. Em sistemas biológicos, sabe-se que não existe um mecanismo para sincronizar as ações dos nodos, nem há restrição para que as suas saídas sejam ativadas em tempos discretos como no modelo MCP (BRAGA, CARVALHO e LUDERMIR, 2000).

Sabe-se também que o valor da próxima saída dos nodos biológicos depende enormemente das ativações dos estados anteriores, já que até mesmo os neurotransmissores liberados anteriormente levam algum tempo para se recombinarem, influenciando, assim, as ativações seguintes (BRAGA, CARVALHO e LUDERMIR, 2000).

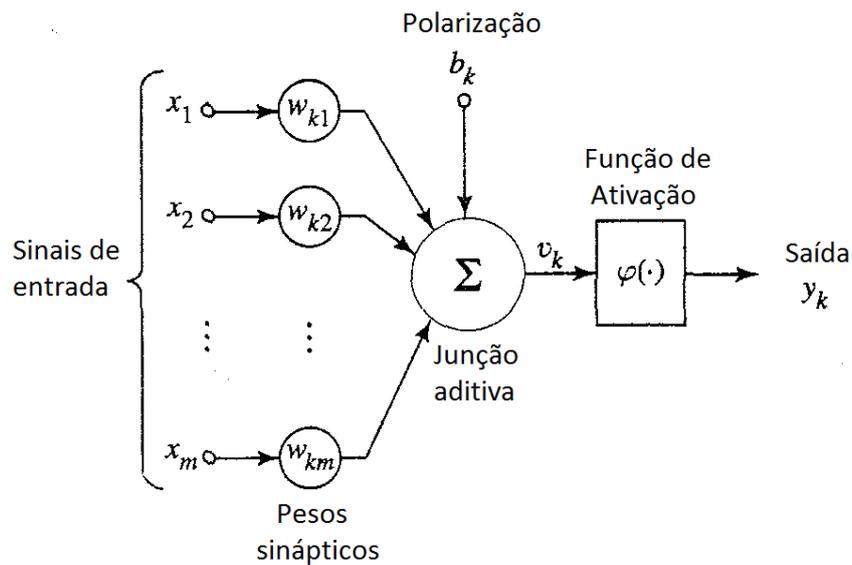


Figura 4: A estrutura do neurônio artificial de McCulloch e Pitts.
Fonte: JUNIOR, 2011

2.5 ARQUITETURAS DAS REDES NEURAIS ARTIFICIAIS.

Fazem parte da definição de arquitetura os seguintes parâmetros: número de camadas da rede, número de nodos em cada camada, tipo de conexão entre os nodos e topologia da rede.

A definição de arquitetura de uma RNA é um parâmetro importante na sua concepção, uma vez que ela restringe o tipo de problema que pode ser tratado pela rede (BRAGA, CARVALHO e LUDERMIR, 2000).

Número de camadas: são os detectores de características, as quais serão representadas, internamente, através dos pesos sinápticos.

Número de nodos em cada camada: faz-se necessário considerar o número de exemplos de treinamento, a quantidade de erro presente nos exemplos, a complexidade da função aprendida pela rede e a distribuição estatística dos dados utilizados no treinamento, para que assim possam ser escolhidos os números de unidades em cada camada.

Ao determinar o número de neurônios em cada camada, os seguintes cuidados devem ser tomados:

- Não utilizar um número de unidades maior que o necessário: número alto de unidades pode fazer com que a rede memorize os dados do treinamento; com isto ela torna-se incapaz de generalizar e, portanto, reconhecer padrões não vistos durante o treinamento.

Isto é chamado de *overfitting*

- Não utilizar um número de unidades inferior ao número necessário: isto pode fazer com que a rede gaste muito tempo para aprender, podendo não alcançar os pesos adequados, ou seja, a rede pode não convergir, ou generalizar demais os padrões de entrada.

(BRAGA, CARVALHO e LUDERMIR, 2000)

A maneira pela qual os neurônios de uma RNA estão estruturados está intimamente ligada com o algoritmo de aprendizagem usado para treinar a rede (HAYKIN, 2001).

A arquitetura das redes neurais encaixa-se em dois grupos distintos:

- Redes feedforward, ou acíclica, onde o grafo que o representa não possui laços entre seus nodos, uma vez que o estado tenha sido ocupado ele não será utilizado posteriormente;
- Redes feedback, ou cíclica, onde o grafo que o representa possui laços entre os nodos, permitindo com que um nodo que já foi acessado seja acessado novamente.

Quanto ao número de camadas, é possível definir a rede de tais formas:

- Rede de camada única, nesta só existe um nó presente para qualquer entrada e saída da rede (Figura 5a, 5e);
- As redes de múltiplas camadas, aonde existe mais de um neurônio entre alguma entrada e alguma saída (Figura 5b, 5c, 5d) (BRAGA, CARVALHO e LUDERMIR, 2000);
- Redes recorrentes, uma rede neural recorrente se distingue de uma rede de múltiplas camadas por ter pelo menos um laço de realimentação (Figura 5e e 5d) (HAYKIN, 2001).

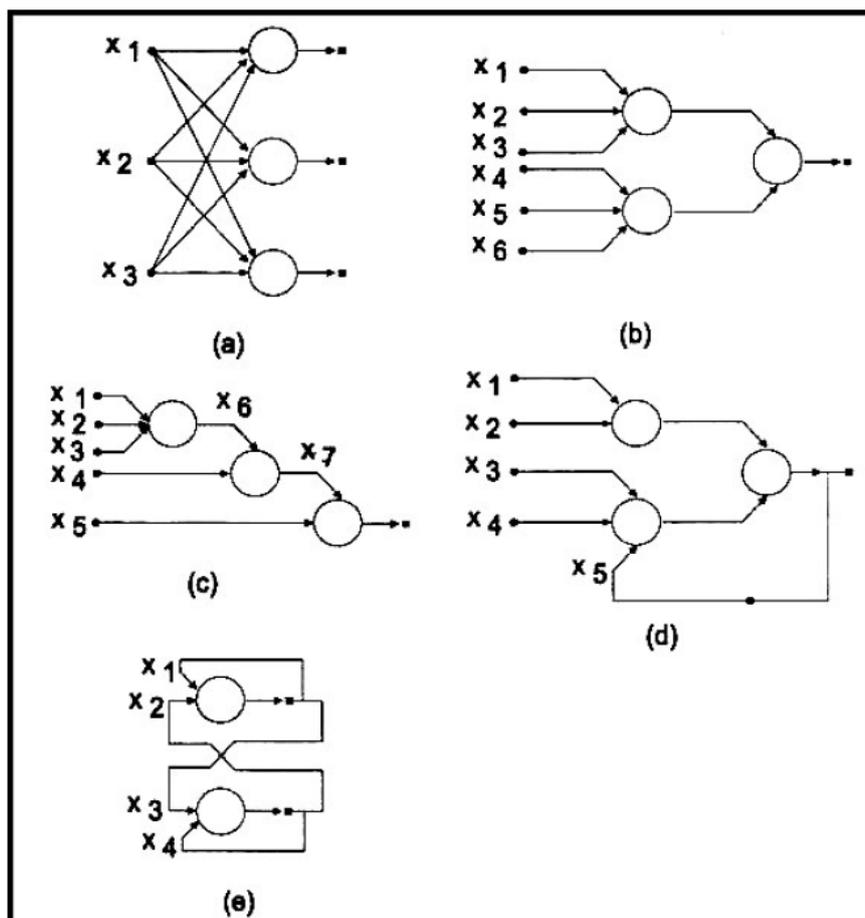


Figura 5: Modelos de Redes (Quantidade de Camadas).
Fonte: BRAGA, CARVALHO e LUDERMIR, 2000

Redes cuja saída única é ligada às entradas comportam-se como autômatos reconhecedores de cadeias, onde a saída que é realimentada fornece o estado do autômato (Figura 5d, 5e).

Se todas as ligações são cíclicas, a rede é denominada auto associativa. Estas redes associam um padrão de entrada com ele mesmo, e são particularmente úteis para recuperação ou “regeneração” de um padrão de entrada (Figura 5e).

Por fim, as redes neurais artificiais podem ser classificadas por sua conectividade:

- Rede fracamente (ou parcialmente) conectada, onde não necessariamente todas as entradas e saídas da rede são conectadas a todos os neurônios da próxima camada (Figura 5b, 5c, 5d);
- Rede completamente conectada onde todos os neurônios têm conexões entre si (Figura 5^a, 5e).

2.6 APRENDIZADO

As redes neurais conseguem “aprender” através da experiência, semelhante a uma criança que aprende a falar, associar objetos, faces e nomes. Isso ocorre através de exemplos demonstrados, tentativa e erro. Dessa forma, a representação de dados para uma problemática, junto a um conjunto de treinamento, faz com que a rede adquira conhecimento. Essa associação é gerada a partir de dados históricos, ou seja, a partir das experiências vividas e de testes realizados anteriormente.

O aprendizado, na maioria das vezes, constitui no ajuste do conjunto de pesos de modo que a rede consiga executar uma tarefa específica. Para se construir um processo de aprendizado é necessário conhecer quais informações estarão disponíveis à rede e como os pesos serão atualizados.

Segundo Silva (2003), existem três paradigmas de aprendizado:

- **Aprendizado supervisionado:** é aquele que utiliza um conjunto de pares (entrada e saída), em que para cada padrão de entrada é especificado um padrão de saída desejado (resposta desejada). O aprendizado ocorre no momento em que a saída é gerada pela rede, a partir dos cálculos efetuados com o padrão de entrada e os pesos correntes. Se a saída for diferente da saída desejada, o algoritmo de treinamento segundo alguns critérios, ajusta os pesos da rede de forma a reduzir o erro. Essa dinâmica é repetida inúmeras vezes para todo conjunto de dados (entrada e saídas) até que a taxa atinja uma faixa considerada satisfatória.
- **Aprendizado não-supervisionado:** este tipo de aprendizado também é conhecido como aprendizado auto supervisionado, e classifica os padrões similares sem utilizar conjunto de pares, isto é, no treinamento da rede são usados apenas valores de entrada. A rede trabalha essas entradas e se organiza de modo a classificá-las mediante algum critério de semelhança. Esse tipo de rede utiliza os neurônios como classificadores, e os dados de entrada como elementos de classificação.
- **Aprendizado híbrido:** combina as duas técnicas apresentadas. Parte dos pesos são determinados pelo aprendizado supervisionado e a outra parte através do aprendizado não-supervisionado.

Pode-se destacar que para cada questão prática e fundamental a respeito da aprendizagem, leva-se em consideração a capacidade de armazenamento da rede e limite de decisões que esta possa tomar, bem como a complexidade de exemplos propostos, dessa forma é determinado o número de padrões de treinamento necessário e quanto tempo a rede em questão irá demorar para adquirir o conhecimento desejado.

Existem diversos tipos de regras de aprendizado, entre as mais básicas estão:

- Aprendizagem por correção de erros – no modelo em questão a correção dos pesos sinápticos é realizada através da comparação da saída almejada com a saída atual, ambas medidas no mesmo instante de tempo. O erro é então definido como sendo a diferença do valor da saída desejado e a saída atual.
Esta função indica o erro rapidamente para a rede e procura adaptar os pesos sinápticos a fim de minimizar a função. Vale frisar que a rede só aprende quando ocorre um erro. Um valor pequeno proporciona uma aprendizagem lenta. Por outro lado, uma taxa alta pode comprometer a estabilidade do sistema, pois a rede pode divergir da solução.
- Aprendizagem Hebbiana - a aplicação desta regra às redes neurais pode ser escrita da seguinte forma. Se dois neurônios, um em cada lado de uma sinapse são ativados simultaneamente, então a força daquela sinapse é seletivamente aumentada. Todavia, se dois neurônios, um em cada lado de uma sinapse, são ativados assincronamente então a força daquela sinapse é seletivamente enfraquecida ou eliminada (SILVA, 2003).
- Aprendizagem de Boltzmann - Esse método de aprendizagem tem suas origens na teoria da computação além de contar com algumas considerações da teoria da termodinâmica. Chamada de Máquina de Boltzmann, a rede neural é formada por uma rede recorrente simétrica operando em somente dois estados, -1 e 1 , e é caracterizada por uma função de energia cujo valor é determinado pelos estados dos neurônios. A atualização dos estados dos neurônios é feita de forma aleatória e acontece até que um mínimo da função de energia seja alcançado. Cada neurônio é, na verdade, uma unidade estocástica que gera uma saída de acordo com a distribuição de Boltzmann dos mecanismos estatísticos (SILVA, 2003). Os neurônios de uma máquina de Boltzmann se dividem em dois grupos funcionais: os visíveis e os ocultos. Os neurônios visíveis fornecem uma interface entre a rede e o ambiente

em que ela opera, enquanto que os neurônios ocultos sempre operam livremente (HAYKIN, 2001).

- Aprendizado competitivo - no aprendizado competitivo os nodos são projetados de tal forma que somente um deles está ativo após a computação de determinada tarefa. Cada nodo possui um mecanismo de neutralização dos demais, logo, se um nodo for ativado, ele é o único a fornecer uma saída do sistema, pois ele anula os demais (SILVA, 2003).

Em uma rede neural competitiva são encontrado conjuntos de nodos que estão interligados em diversas sinapses aleatoriamente distribuídas com pesos diversos de forma que cada nodo possui uma resposta única para determinada entrada, além disso existe um limite na força de cada nodo, dessa forma um mecanismo poderá permitir que os neurônios compitam pelo direito de responder a determinados conjuntos de entrada a fim de garantir que, determinado nodo, se torne especialista em determinados padrões de entrada.

Dessa forma a rede é imposta a um paradigma de aprendizagem, um modelo de ambiente na qual ela irá operar. Basicamente, os algoritmos de aprendizagem diferem entre si pela forma como é formulado o ajuste de um peso sináptico de um neurônio. (HAYKIN, 2001).

3. REDE HOPFIELD

A memória humana funciona como uma memória endereçada pelo conteúdo, por exemplo, muitas vezes uma pessoa pode lembrar de fatos inteiros tendo inicialmente uma pequena lembrança do acontecimento. A Rede Hopfield funciona exatamente como uma memória endereçada pelo conteúdo também chamada de memória associativa.

A Rede Hopfield emprega um princípio chamado de armazenamento de informação como atratores dinamicamente estáveis. A recuperação de informação acontece via um processo dinâmico de atualização dos estados dos neurônios, sendo que, o neurônio a ser atualizado, é escolhido randomicamente (SILVA, 2003).

3.1 MEMÓRIA ASSOCIATIVA

As Redes Neurais de Hopfield (HNN, Hopfield Neural Networks) são redes com realimentação apresentadas por John Hopfield em 1982. As HNNs podem ser utilizadas como memórias associativas, na qual a HNN É capaz de armazenar informações baseadas em alguns de seus estados (HAYKIN, 1994). Além disso, as HNNs podem resolver problemas de otimização combinatória.

A rede de Hopfield atraiu muita atenção na literatura como uma memória endereçável por conteúdo. Nesta aplicação, conhecemos os pontos fixos da rede a priori já que correspondem aos padrões a serem armazenados. Entretanto, os pesos sinápticos da rede que produzem os pontos fixos desejados são desconhecidos, e o problema é como determina-los. A função primária de uma memória endereçável por conteúdo é recuperar um padrão (item) armazenado na memória em resposta à apresentação de uma versão incompleta ou ruidosa daquele padrão.

Sendo uma propriedade importante de uma memória endereçável por conteúdo, a habilidade de recuperar um padrão armazenado, dado um subconjunto razoável de um conteúdo de informação daquele padrão. Além disso, uma memória endereçável por conteúdo é autocorretiva no sentido de que pode corrigir informações inconsistente contida nos indícios a ela apresentados (HAYKIN, 2001).

O modelo de Hopfield consiste de um conjunto de neurônios e um conjunto correspondente de atrasos unitários, formando um sistema realimentado de múltiplos laços. O número de laços de realimentação é igual ao número de neurônios. Basicamente, a saída de cada neurônio é realimentada, através de um elemento de atraso unitário, para cada um dos outros neurônios da rede (HAYKIN, 2001). Dessa forma não existe auto realimentação na rede.

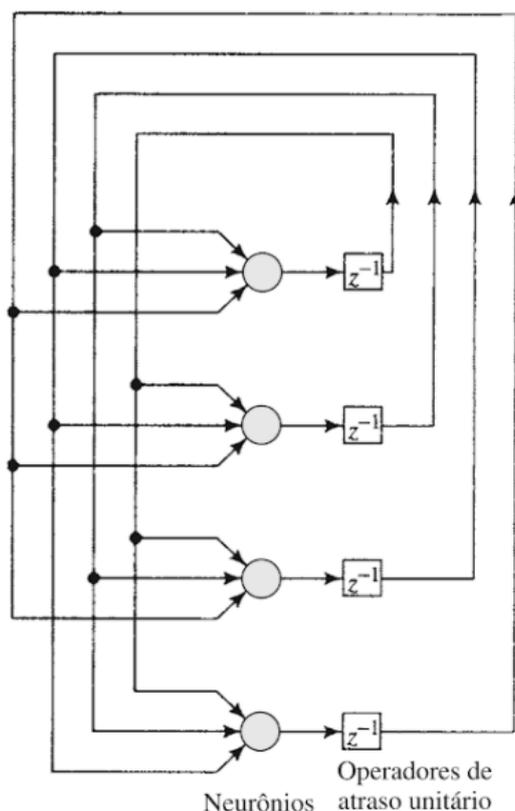


Figura 6: Grafo arquitetural de uma rede de Hopfield consistindo de quatro neurônios.
Fonte: (HAYKIN, 2001)

Neste caso, a HNN possui uma função de energia que prove uma medida de desempenho para o problema de otimização, que por sua vez possui um conjunto grande, mas finito, de possíveis soluções (JUNIOR, 2011).

3.2 MODELO DE HOPFIELD

As HNN são construídas com neurônios de MCP. Desta forma, cada neurônio possui um somatório do conjunto de entradas ponderadas (U_i) e uma saída (V_i), que é o resultado da aplicação de uma função de ativação sobre U_i . A saída V_i após um atraso de tempo, e

aplicada as entradas dos outros neurônios, ponderada por um peso sináptico (T_{ij}), e todas as saídas ponderadas são somadas a uma polarização externa (I_i). As saídas dos neurônios podem ser calculadas em função de U_i utilizando a função logística.

A dinâmica de atualização da entrada do neurônio i (U_i) é descrita pela equação:

$$\frac{dU_i}{dt} = -\frac{U_i}{\tau} + \sum_{j=1}^n T_{ij}V_j + I_i,$$

onde τ é a constante de tempo (HOPFIELD, 1984).

A dinâmica de qualquer sistema do tipo Hopfield com uma matriz de conexão simétrica e governada por uma função de energia definida por:

$$E = -\frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N T_{ij}V_iV_j - \sum_{i=1}^N I_iV_i.$$

O segundo e o terceiro termo da Equação (1) representam a variação de energia da HNN. Assim, a dinâmica do i -ésimo neurônio da HNN pode ser descrita em termos da função de energia (JUNIOR, 2011):

$$\frac{dU_i}{dt} = -\frac{U_i}{\tau} - \frac{\partial E}{\partial V_i}.$$

3.3 FASES DE OPERAÇÃO DA REDE DE HOPFIELD

Podemos apresentar o modelo de Hopfield como uma série de fases operacionais que garantem o funcionamento da rede através do que lhe for imposto.

Inicialmente teremos o processo de aprendizagem, processo esse que considera um conjunto desconhecido de memória fundamentais, utiliza-se da regra do produto externo, ou aprendizagem de Hebb, para calcular os pesos sinápticos da rede. Dessa forma uma vez que eles tenham sido computados, os pesos são mantidos fixos por toda operação. Esta fase também é conhecida como fase de armazenamento.

A operação de inicialização consiste na entrada de um vetor de dimensão N apresentado à rede, fazendo com que o algoritmo de reconhecimento seja iniciado.

De acordo com a regra de interação, o processo de interação até a convergência, alinha os bits e atualiza os elementos do vetor de estado, fazendo este processo de forma

assíncrona e aleatória, mas interagindo com todos os elementos um de cada vez. Esta interação é repetida inúmeras vezes até que o vetor de estado permaneça imutável em seu fim.

Por fim após encontrar um vetor de estado imutável, é gerada a determinação de saída, onde esse vetor é apresentado, realizando a apresentação dos resultados a partir de um vetor de entrada possivelmente ruidoso.

3.4 ARMAZENAMENTO

A capacidade de armazenamento da rede apresentado por Hopfield está atrelada a tentativa de padrões possíveis armazenáveis.

O valor da capacidade da rede está ligado a aceitabilidade de erros durante a recuperação de informação. Dessa forma o erro é proporcional a probabilidade da capacidade ser maior que 1. A medida que tenta-se aumentar o número de padrões armazenados, o número de possíveis erros cresce de forma correspondente (JUNIOR, 2011).

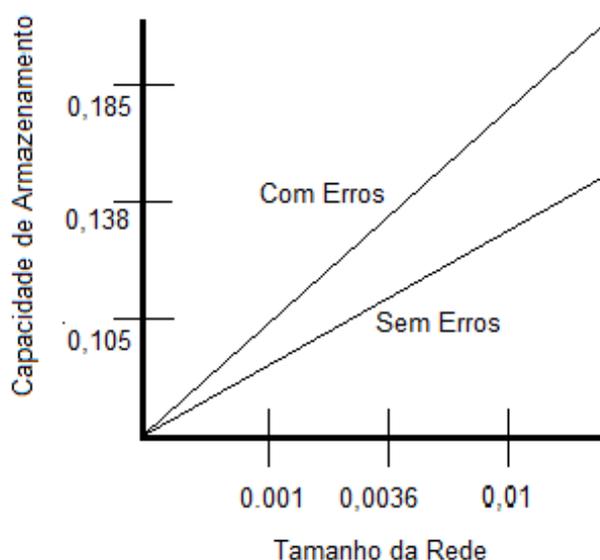


Figura 7: Representação de estado de mistura tripla.

Uma limitação importante da rede de Hopfield é que a sua capacidade de armazenamento deve ser mantida pequena para que as memórias fundamentais sejam recuperáveis.

A capacidade de armazenamento da rede de Hopfield aumenta essencialmente de forma linear com o tamanho N da rede (HAYKIN, 2001).

3.5 ESTADOS ESPÚRIOS

Os estados espúrios representam estados estáveis da rede de Hopfield que são diferentes das memórias fundamentais da rede.

Além dos estados estáveis armazenados existem alguns outros estados, que também são mínimos, em que a rede se estabiliza. Dentre estes destacam-se: estados reversos, estados misturados e spin glass:

- Memórias fundamentais inversas – Estes estados espúrios são versões invertidas, ou negativas das memórias fundamentais da rede; veja por exemplo, o estado apresentado na Figura 7. Para explicar este tipo de estado espúrio, notamos que a função de energia E é simétrica no sentido de que o seu valor permanece imutável se os estados dos neurônios forem invertidos (o estado x_i é substituído por $-x_i$ para todo i). Esta inversão de sinal não constitui um problema para a recuperação de informação se for estabelecido que todos os bits de informação de um padrão recuperado sejam invertidos se for constatado que o bit designado como de “sinal” é -1 em vez de $+1$ (HAYKIN, 2001).



Figura 8: Representação do número 6 na forma de memórias fundamentais inversas.

- Estado de Mistura – Um estado de mistura é uma combinação linear de um número ímpar de padrões armazenados (HAYKIN, 2001). Não são iguais a nenhum padrão armazenado, eles correspondem a somatória linear de um número ímpar de padrões estáveis (JUNIOR, 2011). É um estado que podem representar diversas saídas, de

forma estável, porém com interpretações diferentes. Um grande exemplo disso é a Figura 8 que representa um estado espúrio de uma mistura tripla, formando por uma combinação de memórias fundamentais: o negativo do número 1, o número 4 e o dígito 9.



Figura 9: Representação de estado de mistura tripla.

- Estado de Vidro de Spin - Spin Glass em inglês, é um estado espúrio denominado por analogia com os modelos de vidro de spin da mecânica estatística. Estados de vidro de spin são definidos por mínimos locais de cenário de energia que não estejam correlacionados com qualquer uma das memórias fundamentais da rede; como por exemplo o modelo da Figura 10.

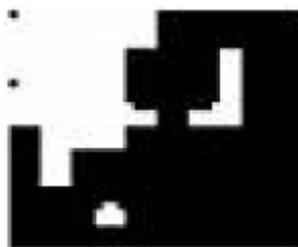


Figura 10: Representação de estado espúrio de vidro de spin.

Os estados reversos ocorrem por causa da simetria existente entre a dinâmica da rede e a energia funcional. Estes estados são mínimos e são recuperados (a rede se estabiliza nestes estados) quando o número de bits diferentes entre o padrão de entrada e o padrão armazenado é igual a mais da metade dos bits (JUNIOR, 2011).

Uma maneira de evitar estes estados é executar a dinâmica da rede até que um padrão válido seja recuperado.

4. PROPOSTA DE TRABALHO

Este trabalho tem por objetivo abordar a proposta de redes neurais artificiais, com ênfase no Modelo de Hopfield, a fim de fomentar a base de conhecimento correlacionada a essa tecnologia, além do desenvolvimento de uma aplicação que tem como embasamento teóricos os conteúdos estudados.

4.1 DESCRIÇÃO DE PROPOSTA

A aplicação utilizada para a identificação de padrões, possui o intuito de fazer com que a rede neural artificial implementada consiga distinguir os padrões que lhe forem propostos. Validando assim o modelo científico proposto por Hopfield e a contribuição de uma implementação capaz de auxiliar no reconhecimento de padrões.

A fim de concluir a abordagem proposta em redes neurais artificiais com ênfase no modelo de Hopfield, algoritmos e estratégias referentes a sua implementação serão estudadas e colocadas a prova, através de análise e pesquisas, tendo como objetivo apoiar o desenvolvimento da área disseminando conhecimento, além de um exemplo prático da rede neural de Hopfield capaz de realizar o reconhecimento de padrões forma eficiente, dentro do pressuposto pela metodologia.

4.2 TECNOLOGIAS UTILIZADAS

A fim executar de forma prática o que foi apresentado e estudo acima, será utilizado o Code::Blocks, que é uma IDE (Ambiente Integral de Desenvolvimento), capaz de auxiliar na codificação e compilação do algoritmo que será necessário para validar as tratativas de ruídos do modelo de Hopfield. Esse ambiente é responsável por viabilizar um ambiente que facilita no desenvolvimento de sistemas em C, C++ e Fortran, tendo seu código aberto e sendo multiplataforma.

Para a linguagem utilizada, foi utilizada a linguagem C, uma linguagem de programação compilada de propósito geral, estruturada, imperativa e procedural. Sendo uma das

linguagens de programação mais populares, possuindo poucas arquiteturas que não suportem compiladores para C.

4.3 METODOLOGIA DE ANÁLISE

Com o intuito de validar e verificar a proposta de Hopfield, foi realizada pesquisas das principais solutivas que tiveram como arcabouço a rede neural proposta pelo mesmo. Sendo apresentados seus principais objetivos, bem como a tecnologia proposta tornou isso capaz ou como auxilia no desenvolvimento e melhoria da solução para aquela problemática.

Foram estudadas diversas áreas e diversas soluções que se utilizam desta tecnologia, podendo estas fazer uso primordial da rede neural, ou parcial da mesma. Dentre as áreas estudadas podemos citar: reconhecimento e detecção de padrões, fazendo uso de dados ruidosos, reconstrução de imagens e dados ruidosos, detecção de padrões e reconhecimento de objetos através de modelo previamente apresentado.

Através da computação paralela a rede neural atua em todos os dados simultaneamente. Isto lhe dá a capacidade de realizar algumas tarefas desejadas por muitos sistemas (JUNIOR, 2011).

5. DESENVOLVIMENTO DO TRABALHO

Com o objetivo de validar a rede neural artificial proposta por Hopfield e analisar possíveis soluções que ele trouxe para os dias de hoje, este trabalho apresenta além da pesquisa na área de inteligência artificial e redes neurais artificiais, um exemplar prático do que foi estudado, bem como uma pesquisa e análise de soluções que fazem o uso destas tecnologias.

Para efetuar o desenvolvimento de um algoritmo de simulação para validação das características da Rede de Hopfield, foi utilizado a IDE Code::Blocks, fazendo-se uso da linguagem de programação C, de forma a simplificar a codificação e trabalho.

5.1 ALGORITMO DE SIMULAÇÃO

De acordo com as características da Rede de Hopfield apresentados nos capítulos anteriores, o algoritmo proposto deverá levar em consideração a frequência de atualização dos estados dos neurônios, de forma que, um neurônio deverá ter a chance de atualizar seu estado de tempos em tempos, levando em consideração que a ocorrência de atualização de dois neurônios requer que o peso sináptico entre eles seja diferente de zero.

Para cada interação existente, os neurônios têm a chance de ter seus estados atualizados, de acordo com uma ordem pré-fixada até que os estados atualizados de todos os neurônios sejam iguais aos seus estados anteriores.

O primeiro passo para a implementação do algoritmo consistiu no armazenamento dos padrões na rede, servindo para a definição dos pesos sinápticos, segundo a regra proposta por Hebb, que foi discutida com mais detalhes nos capítulos anteriores. Os padrões admitidos pela rede são lidos de um arquivo de entrada dentro do próprio algoritmo, sendo passados como parâmetro e os pesos sinápticos só sendo calculados se a condição de que o número de padrões armazenados está de acordo com a capacidade da rede seja condizente.

Após a realização do armazenamento dos padrões pela rede, a rede poderá ser utilizada para recuperação dos padrões. Para a utilização da rede, faz-se necessária a apresentação de um dado de entrada a fim de viabilizar sua inicialização e identificação de um padrão

proposto previamente, vale ressaltar que a rede não irá fazer a recuperação de um padrão se o mesmo não foi previamente armazenado.

Definição e estrutura da rede é dada por:

- Número de Vetores: quantidade de padrões que será possível armazenar nessa rede.
- Área: tamanho dos padrões definidos pela rede, quantidade de pontos de identificação e análise no reconhecimento de padrões e imagens.

```

/* Pontos de Conversão */
#define ZERO_OU_UM(x) ((x)==-1 ? 0 : 1)
#define BINARIO(x) ((x)== 0 ? -1 : 1)

#define NUMERO_DE_VETORES 4
#define X 10
#define Y 10
#define AREA (X * Y)

/* Estrutura da Rede */
typedef struct {
    int pontos;
    int* saida;
    int* limite;
    int** peso;
} net;

```

Figura 11: Algoritmo que define a estrutura da rede.

Dessa forma, o algoritmo realiza os seguintes processos:

- Alocação do Espaço de Memória: nesse processo é alocado na memória o espaço suficiente para que seja possível atender aos números de pontos que o padrão irá receber, o tamanho da rede é definido através de valores atribuídos anteriormente a criação da rede.
- Pontos para Binário: após a definição do tamanho da rede e criação da mesma, as matrizes de aprendizado e de padrões apresentados são calculadas e alimentadas, preparando assim as matrizes para restauração dos padrões.
- Cálculo de Pesos: através de padrões previamente informados, é realizada o cálculo do peso das sinapses, onde é passado em todos os pontos dos padrões definidos e calculados seus pesos para posterior comparação e restauração.

```

void main()
{
    net network;
    int n;

    /* Aloca espaço na memória para a criação da rede */
    createNet (&network);

    /* Preenche os pontos binários da matriz */
    pontosparaBinario (&network);

    /* Calcula o peso da matriz */
    calculandoPesos (&network);

    /* Encontra o caminho mínimo = Reconhecimento do Padrão */
    for (n=0; n<NUMERO_DE_VETORES; n++) {
        encontraLM (&network, notcorrect[n]);
    }
}

```

Figura 12: Algoritmo para inicialização e restauração do padrão.

```

/* Calcula o peso da matriz, realizando assim, o processo de aprendizagem */
void calculandoPesos(net* network)
{
    int i,j,n;
    int peso;

    for (i=0; i<network->pontos; i++) {
        for (j=0; j<network->pontos; j++) {
            peso = 0;
            if (i!=j) {
                for (n=0; n<NUMERO_DE_VETORES; n++) {

                    /* Fórmula principal para calcular o peso da matriz*/
                    peso += apren[n][i] * apren[n][j];
                }
            }

            /* Preenchimento do peso da matriz */
            network->peso[i][j] = peso;
        }
    }
}

```

Figura 13: Algoritmo para calcular pesos sinápticos.

- Restauração de Padrões: mediante a apresentação de um padrão incorreto apresentado, dito como um padrão ruidoso, será realizado a validação dos padrões de forma a calcular e obter de que padrão definido o padrão ruidoso mais se aproxima.

```

      00
      00
    0 0000
    0 00000
      00 000
      0 00 00
    00000000
    00000000
    00      00
    0000000000

```

Figura 14: Entrada de dados com ruídos.

```

      00
      00
      0000
      0 0
      00 00
      0 0
    00000000
    00000000
    00      00
    00      00

```

Figura 15: Saída de dados após treinamento e interação.

5.2 RECONHECIMENTO DE PADRÕES

Existem diversas problemática das quais a rede de Hopfield proporciona soluções atrativas. Entre algumas dessas podemos citar o reconhecimento de padrões, sendo estes apresentados por imagens, dados específicos e outra forma que aderem padrões e que possam ser computados, além do reconhecimento de objetos mediante a estímulo visual.

As redes neurais artificiais consistem em um método de solucionar problemas de inteligência artificial, construindo um sistema que tenha circuitos que simulem o cérebro humano, inclusive seu comportamento, ou seja, aprendendo, errando e fazendo descobertas. São mais que isso, são técnicas computacionais que apresentam um modelo inspirado na estrutura neural de organismos inteligentes e que adquirem conhecimento através da experiência.

Os recursos necessários para armazenar e transmitir imagens são imensos, o que torna atrativa a compressão de imagem (OLIVEIRA, JR. e WALTER, 2004).

Para que seja possível realizar a compreensão de uma imagem e identificação ou reconstrução de uma imagem é necessário treinar a rede para isso.

O treinamento da rede se leva a sucessíveis execuções e apresentações de imagens ruidosas e fim da recuperação correta dos padrões. Esse treinamento ocorre devido a diminuição dos estados que a rede deverá ser possível de acessar posteriormente. Isso garante com que a rede funcione como um sistema de memória por conteúdo endereçável e direcionável. A rede será capaz de recuperar os padrões desejados com apenas uma parcela do conteúdo do padrão original.

Assim sendo, uma rede previamente treinada pode estar apta a realizar a identificação de imagens e compreensão das mesmas, fazendo com que entrada de dados ruidosos, possam ser identificados mais facilmente.

Uma rede inicialmente treinada com imagens contendo pixels brancos e pretos, é capaz de gerar diversos padrões como apresentado nas figuras 17, 18, 19, 20 e 21.



Figura 16: Imagem utilizada para o treinamento da rede utilizando pixels pretos e brancos.
Fonte: OLIVEIRA et. Al

Ao realizar o início do processo de interações a aprendizagem da rede não se mostra eficiente, dado um padrão de entrada o resultado apresentado não é o esperado. Entretanto, quanto mais interações são realizadas, maiores são o acerto da mesma, chegando muito próximo do padrão de entrada, validando seu processo de aprendizagem. Fazendo uso de padrões utilizados no treinamento, a rede responde de forma satisfatória com poucos erros. Para padrões não presentes no treinamento, a rede não apresenta resultados satisfatórios, contudo isto é esperado, pois seria preciso um número maior e diversificado de padrões para o treinamento, e assim a rede conseguiria fornecer outras saídas esperadas (OLIVEIRA et al., 2004).



Figura 17: Imagem de entrada utilizada para o treinamento da rede e saída usando os pesos iniciais (com 1 única iteração).

Fonte: OLIVEIRA et. Al



Figura 18: Saída de imagem após 30 iterações.

Fonte: OLIVEIRA et. Al



Figura 19: Saída de imagem após 120 iterações.

Fonte: OLIVEIRA et. Al

Independente do padrão utilizado, desde que a rede esteja previamente preparada e treinada irá resultar em uma restauração satisfatória.

Quando se tratando de restaurações de imagem baseadas em redes neurais artificiais, verificou-se, de um modo geral, que os modelos estabelecidos se basearam na estimativa dos parâmetros dos modelos presentes (SAĞIROĞLU e BEŞDO, 2012).



Figura 20: Imagem natural utilizada de entrada.
Fonte: SAĞIROĞLU e BEŞDO, 2012



Figura 21: Imagem natural de saída após diversas alterações.
Fonte: SAĞIROĞLU e BEŞDO, 2012

5.2 APLICAÇÕES

As RNAs são conhecidas por superar muitos problemas de modelagem, identificação, controle, filtragem, reconhecimento e classificação. As desvantagens encontradas nesta abordagem foram relacionadas a seleção de pares de texturas apropriados, a observação do nível de ruído, a preparação da entrada e conjuntos de saída e a configuração adequada da rede configurações.

Finalmente, a abordagem sugerida neste trabalho pode fornecer amplas aplicações em Fotogrametria, Sensoriamento Remoto, Visão por Computador, Telecomunicações, etc. devido à sua simplicidade e precisão na restauração (SAĞIROĞLU e BEŞDO, 2012).

Para fazer uso das Redes Neurais de Hopfield, Ali e Kamoun apresentaram uma forma de modelar o menor caminho a partir do estado final da rede neural. O modelo proposto para a rede neural de Hopfield pode ser considerado válido, uma vez que as requisições feitas

à rede nas simulações foram respondidas corretamente. Desta forma, as redes neurais de Hopfield são possíveis em dispositivos FPGA (JUNIOR, 2011).

Segundo LIU et Al. a rede de Hopfield pode ser utilizada para o uso de solução para diversas problemáticas, entre elas a solução de problemas, como problema do rastreamento de alvos e localização tornou-se um dos principais fatores que levaram o ressurgimento do interesse no campo de redes neurais artificiais no início dos anos 90.

A rede de Hopfield atraiu muita atenção na literatura como uma memória endereçável por conteúdo. A função primária de uma memória endereçável por conteúdo é recuperar um padrão (item) armazenado na memória em resposta a apresentação de uma versão incompleta ou ruidosa de uma determinada entrada de dados. (HAYKIN, 2002).

6. CONCLUSÃO

Este capítulo está dividido em duas seções: os Resultados Alcançados e as Projeções Futuras.

6.1 RESULTADOS ALCANÇADOS

Após o estudo realizado o presente trabalho servirá de base teórica para outros estudos na área de inteligência artificial e redes neurais artificiais, visto que essa é uma tecnologia emergente e que tem muito a se desenvolver.

Através do treinamento e métodos de aprendizagem estudados, é possível fazer com que a implementação da rede neural artificial identifique os padrões através de modelos que serviram de dados de entrada para a rede, realizando assim o aprendizado da rede, por meio de diversas iterações.

A identificação de artefatos através de sistemas inteligentes de computadores garante que essa tecnologia possa trazer benefícios ao atuar em diversas áreas como saúde, trânsito e segurança, servindo de solução para problemática como modelagem, identificação, controle, filtragem, reconhecimento e classificação, na qual podemos ver atuando em sensoriamento remoto, visão computacional, telecomunicações, cálculos, restaurações de padrões, entre outras.

O algoritmo implementado serve de arcabouço para futuras pesquisas e estudos com base na rede de Hopfield, bem como a comprovação de que a tecnologia tem muito a crescer e que já pode prover diversas contribuições e facilidades quanto a solução de determinadas problemática.

As principais vantagens da rede de Hopfield dá-se pelo fato da mesma prover auxílio para restauração do conteúdo e identificação de padrão, sendo necessário um treinamento prévio da rede, dessa forma, o índice de satisfação quanto a identificação dos padrões se torna satisfatório, podendo então a rede ser utilizada para atuar e auxiliar em diversas áreas. Dentre as desvantagens da rede é visto com clareza a necessidade de treinamento da rede, fazendo com que o tamanho da rede e o grau de complexidade dos padrões que

serão utilizados interfiram diretamente na complexidade da rede, tornando muitas vezes seu uso e aplicação excessivamente complexo.

Dessa forma as presentes tecnologias serviram de base para o desenvolvimento de novas teorias e tecnologias que possam auxiliar no nosso cotidiano, de forma que possa ser aplicada para facilitar nossas vidas ou simplesmente propor soluções para problemáticas que até então são insolúveis ou complexas demais para serem solucionadas de forma simples.

6.2 PROJEÇÕES FUTURAS

São diversas as tecnologias correlacionadas a área de inteligência artificiais que podem ser estudadas, bem como a comparação dessas tecnologias para a solução de determinadas problemáticas.

Para trabalhos futuros o presente algoritmo poderia ser melhorado e comparado a uma outra estrutura de rede neural artificial.

REFERÊNCIAS

BRAGA, A. P., CARVALHO, A. C. P. L. F., LUDERMIR, T. B. **Redes Neurais Artificiais: teoria e aplicações**. Ed LTC. 2000.

FERNANDES, Anita M. da Rocha. **Inteligência Artificial Noções Gerais**, Florianópolis, Visual Book, 2003.

HAYKIN, Simon. **Neural Networks: A Comprehensive Foundation**. Macmillan, New York, 1994.

HAYKIN, Simon. **Redes neurais: princípios e prática**. Bookman Editora, 2001.

HOPFIELD, John J. **Neural networks and physical systems with emergent collective computational abilities**. Proceedings of the national academy of sciences, v. 79, n. 8, p. 2554-2558, 1982

HOPFIELD, John J. **Neurons with graded response have collective computational properties like those of two-state neurons**. Proceedings of the National Academy of Sciences of the United States of America, v. 81, n. 10, p. 3088-3092, 1984.

JUNIOR, Marcos Antonio da Cunha Oliveira. **Redes neurais de Hopfield para Roteamento de Redes de Comunicação em FPGA**. Trabalho de Conclusão de Curso- Engenharia da Computação, p. 5, 2011.

LIU, Mei et al. **Multi-sensor multi-target passive locating and tracking**. Dianzi Xuebao(Acta Electronica Sinica), v. 34, n. 6, p. 991-995, 2006.

NOBACK, C. R. et al. **The Human Nervous System: Structure and Function**. [S.l.]: Humana Press, 2005. Pdf. ISBN 1588290395.

OLIVEIRA, A. B. V., JR, C. L. N., WALTER, F. **IMPLEMENTAÇÃO DE UM SISTEMA DE COMPRESSÃO DE IMAGENS USANDO REDES NEURAIAS**. Divisão de Engenharia Eletrônica – Instituto Tecnológico de Aeronáutica – ITA, X ENCITA, 2004.

RUSSEL, Stuart J, NORVING, Peter. **Inteligência artificial: tradução da segunda edição**. Rio de Janeiro: Elsevier Editora, 2004.

SAĞIROĞLU, Şeref; BEŞDOK, Erkan. **A Novel Approach for Image Denoising Based on Artificial Neural Networks**. Politeknik Dergisi, v. 15, n. 2, 2012.

SILVA, Juliana Mendes N. **Redes Neurais Artificiais: Rede Hopfield e Redes Estocásticas**. 2003.

TAFNER, M. A.; XEREZ M.; RODRIGUES FILHO I. W. R. – **Redes Neurais Artificiais: Introdução e princípios de neurocomputação**. Ed. EKO. 1995.

VALLE FILHO, Adhemar Maria. **Modelo para Implementação de Consciência em Robôs Móveis**, Tese (Doutorado) – Universidade Federal de Santa Catarina – UFSC Florianópolis, 2003.

VILELA A. L. M. **“Anatomia e Fisiologia Humana – Coordenação e Regulação”**. Disponível em: <<http://www.afh.bio.br/basicos/Nervoso1.htm>>, Janeiro de 2018.