

Relatório Iniciação Científica

Ambientes Para Ensaios Computacionais no Ensino de Neurocomputação e Reconhecimento de Padrões

Bolsa:

Programa Ensinar com Pesquisa-Pró-Reitoria de Graduação

Departamento:

Departamento de Engenharia de Sistemas Eletrônicos da Escola Politécnica da USP

Grupo:

Grupo de Inteligência Computacional, Modelagem e Neurocomputação

Ivan Diego de Sousa

Nusp: 6797098

Orientador: Prof. Dr. Emilio Del Moral Hernandez

São Paulo, 15 de abril de 2011

Resumo do Projeto

Ao longo do projeto metas com o desenvolvimento de ferramental para criação de ambientes computacionais de apoio ao ensino de tópicos de Neurocomputação e Reconhecimento de Padrões, foi escolhido o software MBP desenvolvido pela Universidade de Guarda de Portugal. O ambiente de simulação do software possibilitou potenciais benefícios nas disciplinas de PSI disponibilizando aos alunos maior independência de programas que exigem maior conhecimento de programação e fazendo com que as disciplinas, tais como PSI 2533, PSI 2222 e PSI 2594 possam ter maior foco no conteúdo principal.

O projeto foi subdividido em duas partes: **Redes Neurais Clássicas** e **Redes Neurais Pulsadas**.

Com o objetivo de implementar o MBP foi proposto um exercício-problema abordando o seguinte enunciado: Sinais serão fornecidos de uma fonte geradora desconhecida e será construído um estimador neural capaz de prever os valores do sinal no instante posterior, isto é, dado o valor do sinal nos instantes n e anteriores (ex.: $n-1$, $n-2$,...), o estimador deve dizer o valor para o instante $n+1$. Ao longo do projeto desenvolvido a topologia e a configuração da rede que melhor resolve o problema tanto em questão de tempo de execução quanto de aprendizagem.

Com o foco de por em discussão as idéias de John Hopfield que propôs um modelo de redes neurais pulsadas onde as distâncias entre os pulsos em relação ao tempo são usadas para codificar a informação a ser passada. Ou seja, a amplitude de um sinal DC seria transformada em um atraso de tempo, e dependendo do tamanho desse atraso, poderíamos identificar a amplitude do sinal enviado, transmitindo assim a informação codificada. Com o modelo proposto iremos desenvolver um circuito com características oscilatórias para exemplificar a geração de pulsos geradas nos terminais nervosos do cérebro e conseqüentemente fazer análises dos dados e interpretações das informações fornecidas.

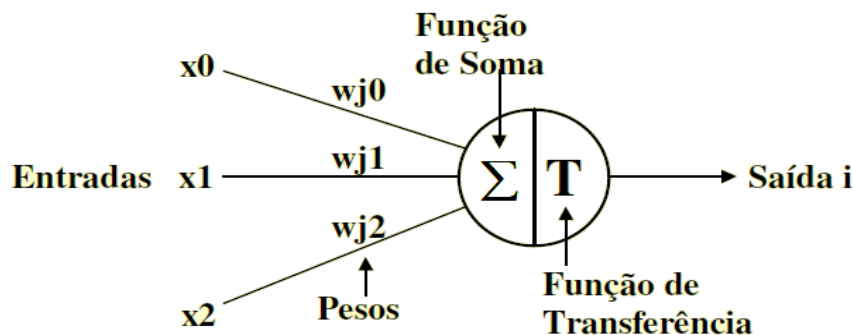
SUMÁRIO

Redes Neurais Clássicas.....	4
Arquitetura básica.....	5
Aprendizagem de redes neurais simples.....	5
Topologia.....	6
Aprendizagem de rede neural complexa.....	7
Dados gerados antes do teste.....	8
Dados obtidos após o aprendizado.....	9
Redes Neurais Pulsadas.....	11
Código.....	11
Proposta de Hopfield.....	12
Circuito.....	15
Circuito do Oscilador.....	13
Gráfico da oscilação do capacitor.....	15
Gráfica Frequência (kHz) x tensão (V).....	15
Gráfico Fase (ms) x Amplitude (V)	16
Gráfico Fase (ms) x Tensão (V)	16
Conclusões.....	17
Bibliografia.....	18

Introdução teórica

Redes Neurais Clássicas

Os modelos neurais procuram aproximar o processamento dos computadores ao cérebro, tentando imitar as habilidades do sistema nervoso, usando neurônios artificiais simples e conectados entre si. São técnicas computacionais que apresentam um modelo inspirado na estrutura neural de organismos inteligentes e que adquirem conhecimento através da experiência. Esse modelo tem como principais aplicações o reconhecimento de padrões e a aproximação de funções. A idéia é um neurônio receber várias entradas, e com pesos pré-atribuídos para cada entrada e uma função de transferência.




Fonte da figura: ~ref [http://fu2re.wordpress.com/; abril 7, 2011 por Marcellus.]

Neurônio artificial projetado por McCulloch

Esses pesos para cada variável de entrada são ajustados com o objetivo de tornar precisa a relação entrada/saída através de testes prévios, e esse processo é chamado de treinamento. Assim, um neurônio é ligado em vários outros, recebendo entradas calculadas por outros neurônios e calculando novas saídas.

Arquitetura básica

Sejam duas camadas I e J de neuronios totalmente conectados como ilustrado. Essas duas camadas são denominadas camadas de entrada e saída, respectivamente. Os neuronios da camada de entrada apenas transmitem pulsos aos neuronios da camada de saída que são os unicos a realizar processamento sobre esses sinais.



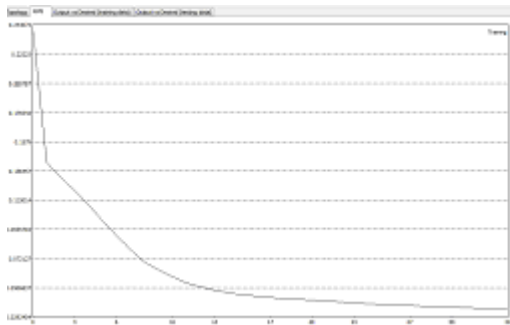
Fonte da figura: ~ref[Simões Alexandre S. Aprendizado não-supervisionado em redes neurais pulsadas de base radial, 2006. 184f.]

Os índices i e j são os pesos


A princípio foi gerado a partir de dados fornecidos, mas aleatórios, funções conhecidas como seno, cosseno e tangente. Trabalhando com um numero pequeno de neurônios e de camadas e com um valor alto de RMS. Cada neurônio artificial pode ser configurado de acordo com a equação que se assemelha com um neurônio biológico no caso escolhemos a sigmóide, pois função de transferência não linear do tipo sigmóide preserva o fenômeno da saturação e a monotonicidade na faixa dinâmica. Os neurônios podem ter equações diferentes entre eles. A variação dos pesos na equação diferencial tende a minimizar o RMS até que o mesmo seja menor que a variação desejada.

APRENDIZADO DE REDES NEURAIS SIMPLES

Valor eficaz (RMS)




Função sigmóide




Fonte da figura: ~ref [dit.ipg.pt/MBP/]


seno



cosseno




tangente



Depois de testes para maior conhecimento do software com a formatação de uma rede simples e funções simples podemos construir uma arquitetura mais complexa para gerar funções desafiadoras. Com o fornecimento de um numero grande de dados ter-se-á que desenvolver uma rede neural e uma configuração do programa muito detalhada e complexa para que possa processar essa quantidade elevada de dados. Para desafio do projeto foi proposto construir um estimador neural capaz de prever os valores do sinal no instante posterior, isto é, dado o valor do sinal nos instantes n e anteriores (ex.: $n-1$, $n-2$,...), o estimador deve dizer o valor para o instante $n+1$.

TOPOLOGIA

Vamos configurar a topologia identificando o numero de neurônios de entrada, o numero de neurônios em cada camada. A topologia adotada para resolução é 15 neurônios de entrada, 25 neurônios ocultos e 1 neurônio de saída. Abaixo temos o gráfico da topologia da rede neural.




Fonte da figura:ref[dit.ipg.pt/MBP/]

Com o MBP podemos configurar a taxa de aprendizagem, o critério de paragem entre outros parâmetros que podem ser alterados para melhorar a aprendizagem da rede neural.


O primeiro gráfico ilustra o decaimento do RMS até o valor de 0,05 em relação ao numero de aprendizagem.

APRENDIZAGEM DA REDE NEURAL COMPLEXA

Output x Desired (training data)




RMS




Erros avaliados sobre o conjunto de treinamento

Output x Desired (testing data).



RMS



Erros avaliados sobre o conjunto de treinamento

Os dados gerados pela rede podem ser observados a cima, o gráfico ilustra com a cor preta o valor ideal e com a cor vermelha a saída gerada pela rede neural. Os gráficos abaixo foram extraídos dos gráficos a cima, mas com um numero menor de entrada com o objetivo de maior facilidade de observação dos resultados.

Com o conjunto de treinamento com 7.000 exemplares foi feito o aprendizado da rede e em consequência foi gerado o primeiro gráfico abaixo. Agora com outro conjunto de treinamento com 3.000 exemplares será feito testes para avaliar o comportamento da rede frente a novos desafios observando a saída da rede neural.


Com os 3.000 dados foi desenvolvido o segundo gráfico abaixo que tendem a se comportar dentro do esperado com valor de RMS inferior a 0,05.

coluna 1- enumeração das entradas coluna 2- saída desejada e coluna 3- saída da rede

Pattern	Desired Output	Network Output
1	116.180000	3282.446573
2	14.596000	12.580202
3	50.640000	5714.749811
4	115.620000	5.865451
5	16683.000000	15690.757965
6	56.738000	6.949959
7	118.150000	7.015075
8	71.962000	4587.949053
9	26.720000	4549.591170
10	82.044000	837.359325
11	102.510000	6.086684
12	59.030000	1113.380148
13	118.470000	1641.602654
14	59.701000	2009.784975
15	22409.000000	6.114771
16	71.985000	5.878972
17	113.770000	73.200234
18	23.325000	52.155779
19	74226.000000	81417.530833
20	111.840000	5649.972398
21	30047.000000	6.706100
22	88.968000	10.106261
23	90878.000000	92416.906546
24	87.117000	990.549517
25	94296.000000	90149.729941
26	79.783000	59.206467
27	105.620000	2330.214572
28	50.000000	6516.092938
29	115.210000	27.507022
30	18.171000	775.792268

Fonte da figura:ref[dit.ipg.pt/MBP/]

Dados gerados antes do teste



Série1: saída desejada

Série2: saída da rede

Eixo vertical: saída


Eixo horizontal: enumeração das entradas

coluna 1- enumeração das entradas coluna 2- saída desejada e coluna 3- saída da rede

Pattern	Desired output	Network output
1	114.680000	8.204112
2	20.069000	5.851019
3	66016.000000	6.656849
4	117.310000	10150.815574
5	10392.000000	5.862831
6	37.494000	13648.836750
7	101.830000	124.418630
8	60.914000	6.066130
9	118.470000	95552.751662
10	59.567000	3196.556593
11	22361.000000	244.839516
12	71.867000	1700.406341
13	113.860000	119.707964
14	22.997000	109.641068
15	73.430000	2007.303418
16	112.560000	7.907613
17	27555.000000	9778.987905
18	83.849000	68774.722732
19	99777.000000	2040.752964
20	66.418000	6.819186
21	117.140000	31101.995751
22	11.012000	636.533552
23	39505.000000	55.157146
24	104.670000	272.975514
25	52807.000000	19593.983590
26	116.800000	6.004413
27	12315.000000	88373.259100
28	43.652000	5.851621
29	109.700000	5.917190
30	37.182000	96717.611961

Fonte da figura:ref[dit.ipg.pt/MBP/]

Dados obtidos após o aprendizado



Série1: saída desejada

Série2: saída da rede

Eixo vertical: saída

Eixo horizontal: enumeração das entradas

Fundamentos das Redes Neurais Pulsadas

Um dos objetivos da inteligência artificial ao longo dos anos tem sido simular o funcionamento do cérebro humano em um modelo computacional. Com o objetivo de criar um modelo mais fiel possível ao cérebro humano uma questão de grande importância e que iremos abordar ao longo do projeto é: Como representar a informação através de pulsos temporais.

Código

Código é a forma com que uma rede neural pulsada representa a informação através dos neurônios – são vastas na literatura. Os impulsos elétricos gerados na saída dos neurônios biológicos podem representar informação em uma ampla gama de formas distintas, cada uma das quais suas especificidades e aplicabilidades.

De modo geral a presença ou ausência de pulsos parece ter forte relevância para neurônios biológicos, enquanto sua forma e tamanho não (independente de escala). Algumas das codificações mais frequentes são descritas a seguir:

Taxa média de disparos

A taxa média de disparos não constitui propriamente uma representação temporal da informação. Há ao menos três noções diferentes de taxas são usualmente utilizadas nos trabalhos com neurônios: i) média sobre o tempo ;ii)média sobre repetições.

Media sobre o tempo.


O sinal é definido pela quantidade de pulsos gerados e um intervalo de tempo.



Fonte da figura:--ref[Simões Alexandre S. Aprendizado não-supervisionado em redes neurais pulsadas de base radial, 2006. 184f.]

Media sobre repetições.


Se um neurônio disparar diversos pulsos na sua saída, um observador pode, para cada intervalo de tempo contar o numero de disparos ocorridos sobre todas as repetições do experimento. Taxa média de disparo por repetições.



Fonte da figura:--ref[Simões Alexandre S. Aprendizado não-supervisionado em redes neurais pulsadas de base radial, 2006. 184f.]

Latência (ou atraso).


Trata-se do intervalo de tempo entre um dado evento e a chegada dos pulsos a alguma das sinapses do neurônio. É considerada de grande relevância neste contexto a chegada do primeiro pulso (HOPFIELD, J, 1995.).



Fonte da figura:--ref[Simões Alexandre S. Aprendizado não-supervisionado em redes neurais pulsadas de base radial, 2006. 184f.]

Fase

Se o sinal de referência for periódico a codificação pelo tempo pode ser utilizada para produzir um novo modelo de codificação. Os pulsos entram em fase com estímulo externo.



Fonte da figura:--ref[Simões Alexandre S. Aprendizado não-supervisionado em redes neurais pulsadas de base radial, 2006. 184f.]

Após uma serie de detalhes sobre redes neurais vamos focar na idéia de Hopfield que acredita que a informação é representada pelo intervalo de tempo entre os pulsos (latência).


Proposta de Hopfield

John Hopfield propôs um modelo de redes neurais pulsadas onde as distâncias entre os pulsos em relação ao tempo são usadas para codificar a informação a ser passada. Ou seja, a amplitude de um sinal DC seria transformada em um atraso de

tempo, e dependendo do tamanho desse atraso, poderíamos identificar a amplitude do sinal enviado, transmitindo assim a informação codificada.


Integra-e-dispara

Esse modelo de integra-e-dispara muito utilizado pela sua simplicidade é baseado no princípio de oscilação. Na figura abaixo vemos a corrente sendo distribuída entre o resistor e o capacitor. O capacitor após encher de carga “vira um aberto” e rapidamente é descarregado gerando um pulso. Esse circuito gera um sinal pulsado.¹



Fonte da figura:~ref[Simões Alexandre S. Aprendizado não-supervisionado em redes neurais pulsadas de base radial, 2006. 184f.]

Sinal gerado pelo circuito a cima.




Fonte:~ref [<http://www.eletronica24h.com.br/cursoEI/cursoEI2/aulas/Aula05.html>]

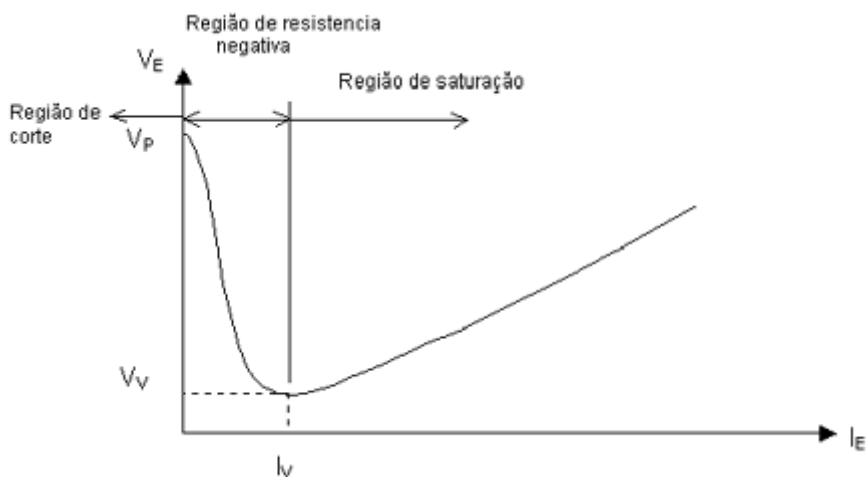
Desenho Esquemático

O circuito abaixo é um modelo característico de um oscilador de relaxação, com o UJT como elemento não linear. Esse transistor seria responsável pelos pulsos do circuito, pois inicialmente ele não conduziria fazendo com que o capacitor carregasse até a tensão limiar do transistor, uma vez atingido esse ponto, ele ativaria, fazendo o capacitor descarregar até que se atingisse a sua tensão mínima, onde novamente ele deixaria de conduzir fazendo com que o capacitor carregasse novamente e assim sucessivamente.¹

- Circuito do Oscilador de relaxação com UJT como elemento não-linear:



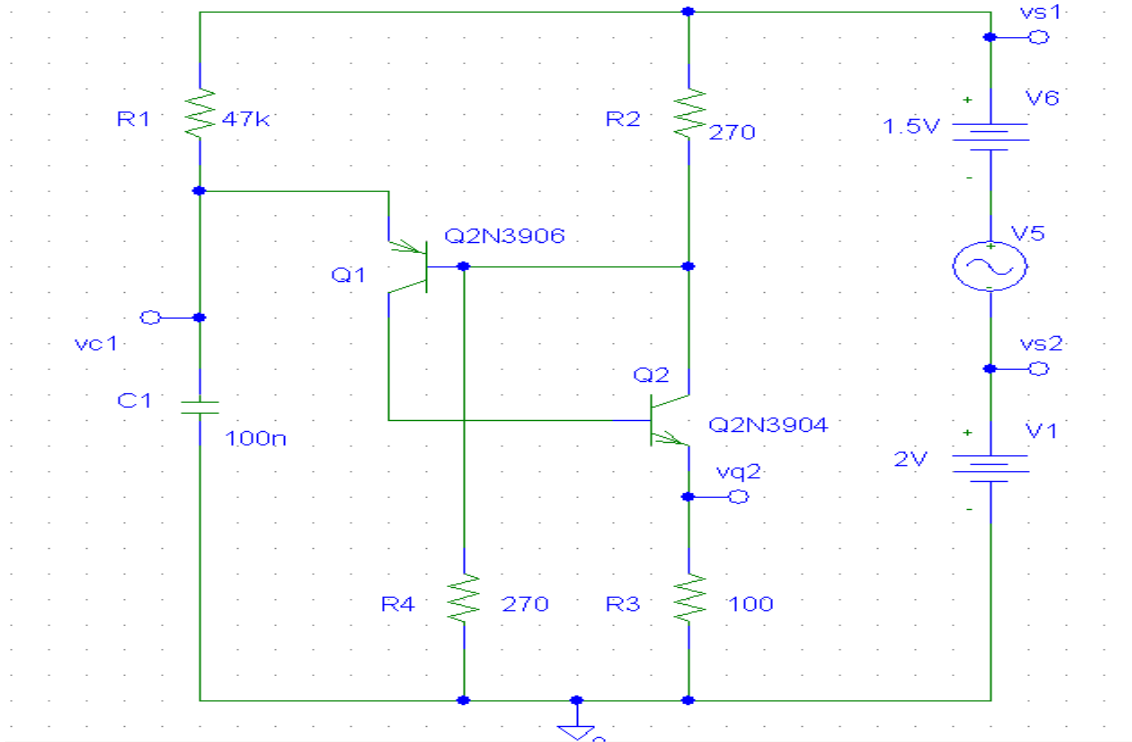
Fonte:~ref [<http://www.eletronica24h.com.br/cursoEI/cursoEI2/aulas/Aula05.html>]



Fonte:~ref [<http://www.eletronica24h.com.br/cursoEI/cursoEI2/aulas/Aula05.html>]

Curva característica do UJT

- Circuito implementado do oscilado de relaxação com modelo equivalente:



Acima temos o projeto de nosso circuito, com dois transistores bipolares associados de modo que se equivalem ao UJT. Ele funciona a partir de uma fonte DC (V1) que alimenta o circuito e uma fonte AC (V5) associado com outra DC (V6) para simular o marca passo biológico.¹

O procedimento descrito no item acima é representado pelo gráfico abaixo, onde vemos a curva de tensão do capacitor no tempo e percebemos a sua oscilação


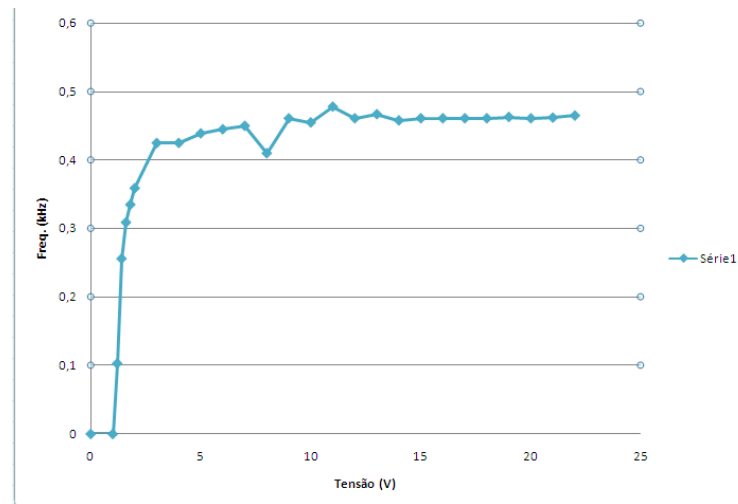


Gráfico da oscilação do capacitor.


Para codificar o circuito precisamos determinar a sua frequência, variamos o valor da fonte DC (V1) para vários valores e identificamos que a frequência satura a partir de 15V. Para continuar o projeto, resolvemos manter a tensão de 2V na fonte DC (V1) porque os valores de tensão e frequência estão longe dos valores de saturação, segundo o nosso gráfico.¹

Gráfica Frequência (kHz) x tensão (V)



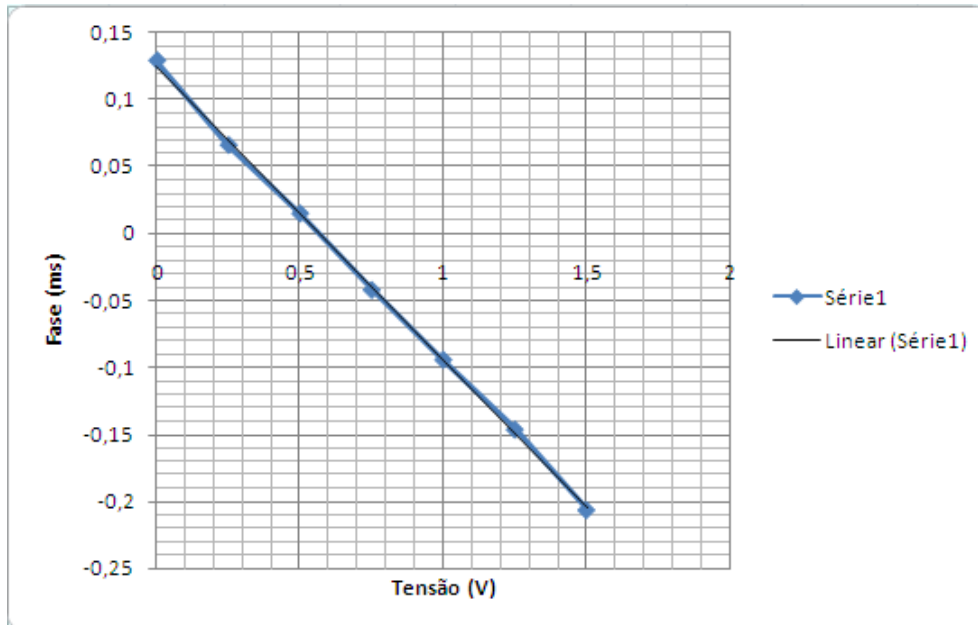
A fonte AC (V5) que simula o marca passo biológico possui frequência de oscilação igual à frequência natural do circuito, sua amplitude foi determinada de modo que a fase dessa fonte fosse constante em relação ao pulso. De acordo com o gráfico abaixo, percebemos que a fase passa ser constante a partir de 2.5V de tensão senoidal.¹

Gráfico Fase (ms) x Amplitude (V)



Poderíamos codificar o circuito utilizando essa característica de que para cada amplitude acima de 2.5V há uma fase diferente, porem, segundo o modelo do Hopfield, não é assim que acontece no neurônio biológico. A codificação é feita por tensão então, adicionamos outra fonte DC (V6) ao circuito, e descobrimos que para cada valor DC (V6) acima de 2.5V já amplitude da fonte AC (V5) conseguimos uma nova fase. Esse ensaio esta representado no gráfico abaixo.¹

Gráfico Fase (ms) x Tensão (V)



¹ Fonte: -ref[PSI 2222 - Práticas de eletricidade e eletrônica II, Implementação eletrônica de redes neurais pulsadas, 2010, Escola Politécnica da USP, São Paulo, 2010]

Conclusões

Cerca de 10.000 sinais foram adquiridos de uma fonte geradora desconhecida. Com os primeiros 7.000 exemplares foi configurada a rede utilizando para cada neurônio a função sigmóide e configurando a arquitetura da rede neural para o treinamento da rede. Após ter gerado os gráficos e dados analisamos o comportamento tanto da fonte geradora quanto da arquitetura da rede. Já treinada a rede neural foi feito testes para observar o comportamento da mesma utilizando os 3.000 exemplares concluindo que para os novos sinais a rede se limita ao valor estipulado de RMS . Concluindo a proposta inicial que era dado o valor do sinal nos instantes n e anteriores (ex.: $n-1$, $n-2$,...), o estimador deve dizer o valor para o instante $n+1$.

Simulando o circuito obtém-se a curva de pulso do capacitor, que se carrega e descarrega caracterizando um oscilador de relaxação. Feito isso, analisamos o circuito sob o ponto de vista da teoria das redes neurais pulsadas e, segundo a proposta de Hopfield, iniciamos o estudo da codificação do sinal, que foi dividido em três partes: A dependência da tensão de excitação e a frequência de oscilação do circuito, a análise da curva da fase e da amplitude da tensão do marca-passo biológico, por fim, confirmamos que podemos codificar os sinais de saída variando a tensão do marca-passo biológico ao invés de modificar a sua amplitude, que é, basicamente, a proposta de Hopfield.

Bibliografia:

Hernandez E. Geehyuk Lee, and Nabil H. Farhat Fundamental theory and applications, vol 50, no.12, 2003.

Hernandez E. Inteligência computacional e redes neurais em engenharia elétrica, São Paulo: Universidade de São Paulo, 2005.

HOPFIELD, J. Pattern recognition computation using action potential timing for stimulus representation. Nature, v.367, p. 33-36, 1995.

Kovács, Zsolt L. - Redes Neurais Artificiais - Fundamentos e Aplicações, Collegium Cognito, 1996.

Lippmann, Richard P. - An Introduction to Computing with Neural Nets, IEEE - Magazine April 1987.

Simões Alexandre S. Aprendizado não-supervisionado em redes neurais pulsadas de base radial, 2006. 184f. Tese (Doutorado em Engenharia Elétrica)- Escola Politécnica da USP, São Paulo, 2006.