

MINISTÉRIO DA CIÊNCIA E TECNOLOGIA
INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS

INPE-7252-PRP/220

**REDES NEURAIIS NO MODELAMENTO E CONTROLE DE
TOKAMAKS – APLICAÇÃO AO ETE (EXPERIMENTO
TOKAMAK ESFÉRICO)**

PRIMEIRO RELATÓRIO

Luis Filipe de Faria Pereira Wiltgen Barbosa
Gerson Otto Ludwig

**FAPESP – PROCESSO 98/06050-8
DOUTORADO DR-I
Área de Engenharia Nuclear / Fusão Controlada
PERÍODO: outubro 98 a setembro 99**

INPE
São José dos Campos
1999

**REDES NEURAIIS NO MODELAMENTO E CONTROLE
DE TOKAMAKS – APLICAÇÃO AO ETE
(EXPERIMENTO TOKAMAK ESFÉRICO)**

PRIMEIRO RELATÓRIO

Luis Filipe de F .P.W.Barbosa
Gerson Otto Ludwig

**FAPESP - PROCESSO 98/06050-8
DOUTORADO DR-I
Área de Engenharia Nuclear / Fusão Controlada
PERÍODO: outubro 98 a setembro 99**

INPE
São José dos Campos
1999

MINISTÉRIO DA CIÊNCIA E TECNOLOGIA
INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS

**REDES NEURAIIS NO MODELAMENTO E CONTROLE
DE TOKAMAKS – APLICAÇÃO AO ETE
(EXPERIMENTO TOKAMAK ESFÉRICO)**

PRIMEIRO RELATÓRIO

Luis Filipe de F .P.W.Barbosa
Gerson Otto Ludwig

**FAPESP - PROCESSO 98/06050-8
DOUTORADO DR-I
Área de Engenharia Nuclear / Fusão Controlada
PERÍODO: outubro 98 a setembro 99**

INPE

São José dos Campos

1999

**REDES NEURAIIS NO MODELAMENTO E CONTROLE
DE TOKAMAKS – APLICAÇÃO AO ETE
(EXPERIMENTO TOKAMAK ESFÉRICO)**

Luis Filipe de F.P.W. Barbosa¹
Gerson Otto Ludwig²

1 Bolsista da FAPESP e estudante de doutorado do Departamento de Engenharia Eletrônica do Instituto Tecnológico da Aeronáutica - ITA - Engenheiro Eletricista do Projeto Tokamak ETE no Laboratório Associado de Plasma - Centro de Tecnologias Associadas - LAP / CTE / INPE

2 Pesquisador do Laboratório Associado de Plasma - Centro de Tecnologias Associadas - LAP / CTE / INPE e orientador de tese

**Relatório apresentado a FAPESP, referente a bolsa de Doutorado DR-I
Área de Engenharia Nuclear / Fusão Controlada
outubro de 98 a setembro de 99**

RESUMO

Este projeto de pesquisa compreende o projeto e a utilização de Redes Neurais Artificiais (RNA) na reconstrução magnética do equilíbrio do plasma de tokamaks, obtidos através de sondas magnéticas inseridas no interior da câmara de vácuo, que fornecerão informações sobre a posição da coluna de plasma para o sistema de controle do campo magnético vertical. O sistema de controle do campo magnético vertical deverá comandar os amplificadores de alta potência que deverão atuar sobre as bobinas magnéticas de controle de equilíbrio e conformação com o intuito de reposicionar a coluna de plasma do Experimento Tokamak Esférico (ETE), em fase final de montagens no Laboratório Associado de Plasma (LAP) do Instituto Nacional de Pesquisas Espaciais (INPE) em São José dos Campos, São Paulo.

SUMÁRIO

1 - Introdução	1
2 - Controle da Posição da Coluna de Plasma em Tokamaks	3
2.1 - Introdução ao Controle de Posição do Plasma	3
2.2 - Princípio de Funcionamento de um Tokamak e a Importância do Campo Magnético Vertical para o Equilíbrio do Plasma	4
2.3 - Evolução dos Sistemas de Controle da Posição do Plasma em Tokamaks	6
3 - Redes Neurais Artificiais	12
3.1 - Evolução para a Inteligência Artificial	12
3.2 - Redes Neurais Artificiais (RNA)	13
3.3 - Neurônios Biológicos	15
3.4 - Neurônios Artificiais (Matemático)	20
3.5 - Aprendizado e Treinamento de RNA	23
3.6 - Topologias de RNA	26
3.7 - Algoritmo de Treinamento <i>Back-Propagation</i>	26
4 - Proposta do Sistema de Controle da Posição do Plasma no Tokamak ETE Utilizando Técnicas de RNA	30
4.1 - Tokamak ETE (Experimento Tokamak Esférico)	30
4.2 - Tipo de RNA a ser Implementada no ETE	32
4.3 - Reconstrução do Equilíbrio do Plasma no ETE	34
4.4 - Controle Dinâmico do Plasma no ETE	37
5 - Conclusões e Perspectivas	39
Referências Bibliográficas	40
Apêndice A - Simulações Realizadas com o Programa TOPEOL	43
Apêndice B - Seminário apresentado no LAP/INPE em setembro 1999	44

1. Introdução

Este relatório é referente ao primeiro período da bolsa de doutorado da FAPESP (outubro de 98 a setembro de 99).

Durante este período, foi feito um levantamento bibliográfico de Redes Neurais Artificiais, bem como da própria evolução histórica dos sistemas de controle de posição de colunas de plasmas em tokamaks. Além disto, em paralelo foi dado andamento nas atividades acadêmicas para a conclusão dos créditos necessários para o desenvolvimento da tese proposta, Redes Neurais no Modelamento e Controle de Tokamaks – Aplicação ao ETE (Experimento Tokamak Esférico).

O tokamak ETE é uma máquina destinada aos estudos da física de plasmas para a fusão termonuclear controlada, que está em fase final de montagens no Laboratório Associado de Plasmas (LAP) no Instituto Nacional de Pesquisas Espaciais (INPE) na cidade de São José dos Campos - SP.

Neste primeiro relatório, foi abordada a evolução histórica dos sistemas de controle de posição da coluna de plasma em tokamaks e os resultados promissores obtidos com sistemas menos “inteligentes”, e que se mostram importantes para aplicações em tokamaks funcionando como reatores a fusão nuclear. Neste mesmo contexto, foi abordada a técnica de Inteligência Artificial chamada de Redes Neurais Artificiais para aplicação em controle, descrevendo-se suas características, bem como o algoritmo de treinamento escolhido para a aplicação de controle do plasma. E finalmente é apresentada a proposta do sistema de controle da posição de plasma para o tokamak ETE.

Durante o período da bolsa, haverá um maior aprofundamento e a descrição detalhada do sistema de controle da posição do plasma em tokamaks utilizando a técnica de Redes Neurais Artificiais e sua aplicação no tokamak ETE.

No decorrer deste relatório, tem-se:

No capítulo II, é apresentada uma breve descrição da máquina do tipo tokamak e a importância do campo magnético vertical para o equilíbrio do plasma. Neste capítulo também comenta-se a evolução e o funcionamento de alguns sistemas de controle de posição da coluna de plasma em outras máquinas do tipo tokamak.

No capítulo III, é apresentada a evolução das máquinas até o desenvolvimento de técnicas de Inteligência Artificial, a fim de localizar historicamente a técnica de Redes Neurais Artificiais (RNA). Neste capítulo também é apresentado o conceito de RNA, bem com uma comparação do neurônio biológico ao neurônio artificial (matemático) descrevendo os métodos de treinamento e aprendizagem de RNA, sua topologias e o algoritmo de treinamento Back-Propagation.

No capítulo IV, é apresentada a proposta do sistema de controle da posição do plasma no tokamak ETE utilizando técnicas de RNA. Tem-se uma breve descrição do tokamak ETE, do tipo de RNA a ser implementada, o objetivo de reconstrução do equilíbrio do plasma e a possibilidade de implementar o controle dinâmico da coluna de plasma no ETE.

No capítulo V, são apresentadas as conclusões e perspectivas futuras para a conclusão do projeto de pesquisa.

No apêndice A, tem-se algumas simulações realizadas com o programa TOPEOL.

No apêndice B, tem-se o seminário apresentado no LAP/INPE, referente a Redes Neurais Artificiais e a utilização desta técnica para o controle da posição do plasma no ETE.

2. Controle da Posição da Coluna de Plasma em Tokamaks

2.1. Introdução ao Controle de Posição do Plasma

O tokamak é um dispositivo experimental utilizado na investigação do confinamento magnético do plasma de alta temperatura, em condições próximas as necessárias para a fusão termonuclear controlada.

Com o passar dos anos, a pesquisa em fusão termonuclear enfrentou, e ainda enfrenta, dificuldades intrínsecas deste tipo de dispositivo. Para a obtenção de resultados satisfatórios houve um grande esforço dos pesquisadores no sentido de aproveitar ao máximo de cada pulso de energia, chamado de disparo, nos tokamaks. Isto acarretou um enorme tempo de funcionamento destes dispositivos. E levou a necessidade de ajustar (controlar) os disparos dos tokamaks (pressão, temperatura, carga dos bancos de capacitores, equilíbrio do plasma, etc) a fim de obter uma boa repetibilidade entre cada disparo.

Um dos primeiros sistemas de controle empregados em tokamaks foi o sistema de disparo automático, o qual evitava a exaustiva atenção do operador em cada disparo, uma vez que os parâmetros do disparo não se alteravam. A necessidade de segurança também, fez com que fossem desenvolvidos sistemas de controle, que possibilitam controlar os disparos dos tokamaks a distância, obtendo desta forma isolamento galvânica do experimento.

Desde a década de 70, o desenvolvimento da eletrônica permitiu a utilização de sistemas eletrônicos de controle em tokamaks. Principalmente no que se refere ao controle da posição do plasma.

Uma das dificuldades encontradas neste tipo de pesquisa se refere a instabilidades do plasma que em tokamaks tendem a deslocar o eixo magnético da coluna de plasma em relação ao eixo geométrico de equilíbrio do plasma. A correção desta mudança de direção é obtida através da realimentação de corrente elétrica que flui nas bobinas de correção de campo vertical ou na própria bobina de campo vertical

Observa-se que tokamaks que dispunham de sistemas de correção da coluna de plasma, obtinham um melhor aproveitamento dos disparos, uma vez que os mesmos além de ficarem mais estáveis, também obtinham um visível prolongamento do disparo.

A utilização destes sistemas de controle na correção da coluna de plasma, se desenvolveram ao mesmo tempo que as teorias de controle se firmavam e o desenvolvimento tecnológico avançava.

Notadamente este tipo de controle de longe é uma tarefa trivial, devido as dificuldades de modelar o plasma e seu comportamento durante a evolução temporal do disparo. Outro fator importante e que também dificulta o controle é a curta duração de tempo de cada disparo (milissegundos). O sistema de controle deverá então ser sensível o suficiente para atuar durante a evolução do disparo, o que equivale a dizer que o tempo de atuação deverá ser da ordem de microssegundos. Isto implica que o controlador deverá ler os sinais vindos das sondas magnéticas e enviar às fontes de potência os níveis de corrente elétrica necessários para reposicionar a coluna de plasma e restabelecer o equilíbrio do plasma.

Este tipo de controle é de grande importância para o funcionamento dos futuros reatores a fusão termonuclear controlada, uma vez que os mesmos deverão operar com pulsos longos e estáveis.

Na Seção 2.2, é apresentado o princípio de funcionamento de um dispositivo do tipo tokamak e a importância do campo magnético vertical para o equilíbrio do plasma.

Na Seção 2.3, são apresentadas soluções para a correção da posição do plasma em tokamaks, e também, observa-se a evolução histórica deste tipo de controle.

2.2. Princípio de Funcionamento de um Tokamak e a Importância do Campo Magnético Vertical para o Equilíbrio do Plasma

A concepção do tokamak é de origem russa e foi desenvolvida teoricamente por Andrei Sakharov e construída por Lev A. Artsimovich, no final da década de 50.^[01] Sua forma geométrica é toroidal devido à necessidade de diminuir as perdas de partículas energéticas, que ocorriam em máquinas de extremidades abertas. Na Figura 1 pode-se ver o esquema básico de uma máquina tipo tokamak.




Fig. 1 –Esquema básico de um tokamak

Os tokamaks utilizam campos magnéticos intensos, obtidos através de bobinas magnéticas, que confinam o plasma durante um intervalo de tempo (regime pulsado), durante o qual o plasma obtido é diagnosticado, a fim de se verificar os efeitos físicos ocorridos em cada disparo. A união de campos magnéticos distintos (toroidal, poloidal e vertical), forma um campo único helicoidal que é o responsável pelo confinamento da corrente de plasma no tokamak, ver Figura 2.

No tokamak, a formação, o confinamento e o equilíbrio são obtidos através de campos magnéticos gerados pelos sistemas de bobinas que compõem a máquina. A interação destes campos, deve proporcionar as condições ideais de confinamento e equilíbrio do plasma no tokamak.




Fig. 2 – Representação esquemática da configuração de campo magnético helicoidal

Observa-se que o campo magnético toroidal ($\vec{B}_\phi$) é o mais intenso, este é gerado pela corrente que circula na bobina de campo toroidal, a qual é enrolada na direção poloidal. Sabe-se, no entanto, que o campo toroidal não é suficiente para o confinamento perfeito das partículas do plasma em um tokamak^[02]. Sendo assim, deve haver também um campo magnético poloidal ($\vec{B}_\theta$), gerado pela própria corrente de plasma que circula na direção toroidal do tokamak. Há, também, a necessidade de um campo magnético adicional para se obter o equilíbrio da coluna de plasma, que é o campo magnético vertical externo^[03].

O campo magnético vertical externo possui basicamente duas finalidades: compensar a força de expansão da coluna de plasma toroidal, que é proporcional à corrente de plasma, e adicionar uma componente de campo poloidal que permite modificar o formato da coluna de plasma, para obter o equilíbrio^[04].

2.3. Evolução dos Sistemas de Controle da Posição do Plasma em Tokamaks

A implementação de sistemas de controle de campo vertical para a correção da posição da coluna de plasma em tokamaks teve início na década de 70, onde vários sistemas deste tipo foram testados e alguns obtiveram sucesso, utilizando os tradicionais controladores automáticos realimentados^[05-10].

O estudo das instabilidades do plasma e a sua reconstrução magnética para a obtenção do equilíbrio, tornaram o controle do campo vertical uma necessidade operacional. Dentre os controles de campo vertical utilizados nas últimas duas décadas (70 e 80) até a atualidade, destacam-se:

- O sistema de controle do campo vertical do tokamak CLEO^[06] (Laboratório de Culham – Inglaterra – 1974) foi um dos primeiros a utilizar a realimentação dos sinais de corrente de plasma e da posição vertical da coluna, para reposicionar o plasma. Basicamente este sistema utilizava um par de amplificadores de potência transistorizados como uma fonte de corrente elétrica para corrigir o campo vertical externo aplicado. Estes amplificadores podiam gerar aproximadamente 10% da corrente elétrica total requerida para o campo magnético vertical do tokamak CLEO, que era da

ordem de 70kA. Os sinais de entrada do controlador são derivados dos sinais vindos das bobinas de posição e dos valores de corrente de plasma medidos pela bobina de Rogowski, conforme pode ser visto na Figura 3.

O funcionamento deste circuito fez com que houvesse uma sensível diminuição na instabilidade da coluna de plasma, as quais levavam a disrupção, e também promoveu um acréscimo significativo na duração temporal do disparo do tokamak CLEO.




Fig. 3 – Esquema do sistema de controle da posição do plasma no tokamak CLEO^[06]

Observa-se que a variação da posição da coluna de plasma do tokamak CLEO sem o sistema de controle era da ordem de 10cm sem qualquer região de estabilização. Com o funcionamento do servo controle esquematizado na Figura 3, a coluna de plasma se estabilizou durante aproximadamente 100ms com uma faixa de desvio da ordem de 2cm.

- O tokamak ORMAK^[07] (Laboratório Nacional de Oak-Ridge – USA – 1976) utilizou um sistema de controle da posição do deslocamento horizontal da coluna de plasma baseado na teoria de controle ótimo.

O sistema era pré-programado pelas condições e parâmetros de disparo e se modificava conforme a coluna de plasma variava sua posição. A pré-programação era obtida de resultados experimentais e dos modelamentos do plasma e do controle ótimo. A correção da posição também era obtida utilizando amplificadores operacionais que alteravam a corrente elétrica aplicada na bobina de campo magnético vertical. Os sinais dos sensores magnéticos eram integrados e combinados com os sinais de corrente de plasma fornecido pela bobina de Rogowski. A melhor posição para o equilíbrio do plasma no tokamak ORMAK era obtida quando o eixo magnético da coluna de plasma coincidia com o centro geométrico do toroide que forma a câmara de vácuo do ORMAK.

Na Figura 4, pode-se observar um esquema do sistema de controle realimentado da posição do plasma no tokamak ORMAK.




Fig.4 – Esquema dos sistema de controle da posição do plasma no tokamak ORMAK^[07]

Observa-se na Figura 4 que o gerador de função sobrepõe um sinal adicional de correção o qual deve ser proporcional ao desvio de posição do plasma. De forma que, o campo magnético vertical fica estabilizado no início do disparo (formação da corrente de plasma) pelo sinal vindo do gerador de função. Após aproximadamente 5ms, quando o plasma começa a derivar da posição de equilíbrio, entra em funcionamento o circuito de controle realimentado de correção da posição do plasma.

Na Figura 5, mostra-se um disparo típico do ORMAK, na parte *A* o disparo sem o sistema de controle operando e na parte *B* o sistema de controle de posição atuando e restabelecendo o equilíbrio da coluna de plasma, reduzindo a variação de posição para menos de 2cm com uma estabilidade de 60ms.




Fig.5 – Resultados obtidos com o sistema de controle de posição do plasma do tokamak ORMAK^[07]

- O sistema de controle realimentado da posição do plasma do tokamak TNT-A^[08] (Universidade de Tóquio – Japão – 1984), tem um aspecto diferente dos outros sistemas de controle, pois o plasma neste tokamak não era circular. Isto implicava em um outro tipo de modelamento do plasma, interessante pois atualmente os tokamaks não mais operam com plasmas circulares e sim com formato alongado. O sistema de controle era composto por amplificadores de potência com fontes de tensão de 35V e corrente elétrica de 70A. A tensão aplicada nas bobinas de correção do campo vertical eram proporcionais a diferença do campo poloidal medido através de sondas magnéticas, como pode ser observado na Figura 6.




Fig.6 - Esquema do sistema de controle da posição do plasma no tokamak TNT-A^[08]

Este sistema se mostrou eficiente para reestabelecer o equilíbrio do plasma no TNT-A. O desvio da coluna de plasma era corrigido mais eficazmente quando o ganho do sistema de controle realimentado era suficientemente alto. Observa-se que um ganho muito alto saturava a saída do amplificador após o primeiro *overshoot*, com isto limitando o ganho máximo do sistema.

Na Figura 7, tem-se a evolução da corrente de plasma (I_p), da corrente de controle realimentado (I_f) e o desvio da coluna de plasma para vários ganhos do sistema de controle (0, 0,15 e 0,87).

Na primeira coluna da Figura 7, observa-se o disparo com ganho zero, e a coluna de plasma não se estabiliza, e sofre uma deriva de posição da ordem de 6cm. Na segunda e terceira colunas da Figura 7, o sistema de controle esta operando com ganhos de 0,15 e 0,87, para este último ganho, a coluna de plasma se estabiliza em 15ms e com desvio final de aproximadamente 1,5cm.




Fig.7 – Resultados obtidos com o sistema de controle de posição do plasma no tokamak TNT-A^[08]

O que pode ser observado destes sistemas descritos anteriormente é que seu desempenho dependia muito de uma familiaridade com o dispositivo, além de uma boa aproximação teórica e experimental. Observa-se também que estes dispositivos operavam a tempo suficiente para obter a aproximação da teoria de controle com a teoria de equilíbrio de cada plasma.

Em todos os casos os sistemas de controle foram projetados para atender um desvio previamente conhecido e típico dos disparos de cada dispositivo.

Atualmente os sistemas de controle de posição do plasma em tokamaks tem importância fundamental para obter uma longa duração da descarga de energia, ou seja, uma longa duração da evolução temporal da coluna de plasma.

Além dos sistemas de controle clássicos^[06, 07, 08, 09] utilizados em muitos tokamaks para a correção da posição do plasma, também foram testados modelos de controle ótimo^[10,11,12] os quais dominaram os sistemas de controle de posição do plasma na década de 80. Atualmente as novas gerações de tokamaks vem fazendo uso de controle robusto (H_∞), além de sistemas inteligentes utilizando inteligência artificial^[04, 14] (lógica nebulosa e redes neurais artificiais).

3. Redes Neurais Artificiais (RNA)

3.1. Evolução para a Inteligência Artificial

Desde o início da evolução, a raça humana confecciona utensílios e objetos, que mais tarde possibilitaram a construção de máquinas que tinham com objetivo único de facilitar as tarefas humanas. Este fato acarretou e ainda vem acarretando um avanço tecnológico, tendo em vista que a realização de tarefas em menores períodos de tempo possibilitam o estudo e a solução de problemas cada vez mais complexos do cotidiano humano e da própria natureza.

A diminuição no desperdício de tempo em tarefas de menor importância, fez com que os seres humanos pudessem se dedicar mais a outros problemas que dependiam de uma atividade muito mais mental do que física. Este fato foi marcante não só para a evolução humana, como foi determinante para a evolução tecnológica, como a construção de robôs na década de 80.

Observa-se claramente que a evolução das máquinas segue o mesmo caminho da evolução humana. O fato de que os seres humanos não possuem predadores naturais, associado a inteligência e a volição, fez com que a raça humana dispusesse de tempo suficiente para aprender e realizar tarefas, e desta forma dominar o conhecimento de seu habitat.

Desde a confecção dos utensílios pré-históricos até a construção de máquinas sofisticadas, as tarefas exigiam o esforço físico e trabalhos repetitivos, com o passar do tempo além do esforço físico as máquinas também substituíram os trabalhos com maior eficiência e segurança e atualmente o grande desafio da raça humana é dotar de “inteligência” as máquinas para que estas possam realizar tarefas humanas implementando artificialmente o conhecimento^[15,16].

Dotar uma máquina com inteligência é o que o ramo da ciência chamado de Inteligência Artificial estuda. Prover as máquinas com a capacidade de realizar tarefas que exijam atividades mentais similares as realizadas pelo cérebro humano é a evolução natural da tecnologia na fabricação de máquinas.

O estudo da inteligência artificial não contribui apenas para o aperfeiçoamento de máquinas, mas também, para o estudo da integração do homem com seu habitat, fornecendo as informações prioritárias do modo com que os humanos aprendem e estabelecendo desta forma a base da formação do conhecimento^[15].

Para dotar as máquinas com inteligência artificial é necessário utilizar uma técnica, dentre estas técnicas as que mais se destacam atualmente^[15] são:

- Sistemas Especialistas – Buscam observar o conhecimento de especialistas humanos em determinadas áreas do conhecimento utilizando os conceitos de lógica;
- Lógica Nebulosa – Utiliza-se das representações humanas para fenômenos naturais vindos das expressões verbais empregadas no cotidiano;
- Redes Neurais Artificiais – Utiliza-se o princípio de funcionamento do sistema nervoso biológico o qual é baseado em elementos processadores simples denominados neurônios os quais possuem processamento paralelo e conhecimento distribuído.

3.2. Redes Neurais Artificiais (RNA)

O estudo de Redes Neurais Artificiais (RNA) também chamada de neurocomputação, connexionismo ou processamento paralelo distribuído é uma forma alternativa para solucionar problemas complexos onde a utilização de algoritmos (simbólicos ou numéricos) não se mostram apropriados. As RNA são inspiradas no conhecimento atual dos sistemas nervosos biológicos. Mesmo assim, modelos desenvolvidos artificialmente com a utilização da matemática ainda são muito simples, quando comparados aos sistemas biológicos mais simples, como é o caso dos sistemas nervoso dos insetos (mosca e abelha)^[17,18], mostrados na Figura 8. Entretanto apesar das RNA não serem equivalentes na complexidade tanto quanto as redes neurais biológicas, ainda sim, são chamadas de redes neurais devido ao significado histórico do uso da palavra neural, vindo das grandes contribuições científicas no início das pesquisas que surgiram de pesquisadores ligados a área das ciências biológicas.

As redes neurais artificiais, diferentemente dos computadores digitais convencionais, executam suas tarefas utilizando um grande número de processadores, onde cada qual é muito simples, mas interconectado a vários outros processadores semelhantes, operando de forma paralela. Assim sendo, a representação do conhecimento fica distribuída pelas conexões entre os processadores e o aprendizado

(treinamento) é feito alterando-se os valores associados as conexões e não via programação. Entretanto, ainda sim, os métodos de treinamento devem ser especificados para cada problema e precisam ser programados.




Fig. 8 – Gráfico de velocidade de processamento por número de conexões para componentes eletrônicos e seres biológicos^[18]

Devido ao fato de que a área de Inteligência Artificial, mais precisamente a técnica de Redes Neurais Artificiais abranger pesquisadores de quase todas as áreas da ciência, existem dezenas de definições para Redes Neurais Artificiais. Porém a definição proposta em 1990 por Hecht-Nielsen^[19] se mostra mais apropriada:

“Uma rede Neural Artificial é uma estrutura que processa informação de forma paralela e distribuída e que consiste de unidades computacionais (as quais podem possuir uma memória local e podem executar operações localmente) interconectadas por canais unidirecionais chamados de conexões. Cada unidade computacional possui uma única conexão de saída que pode ser dividida em quantas conexões laterais se fizerem necessárias, sendo que cada uma destas conexões transporta o mesmo número de sinal de saída da unidade computacional. Este sinal de saída pode ser contínuo ou discreto. O processamento executado por cada unidade computacional pode ser definido arbitrariamente com a restrição de que este deve ser completamente local, isto é, deverá depender somente dos valores atuais dos sinais de entrada que chegam até a unidade computacional via as conexões e dos valores armazenados na memória local da unidade computacional”.

Assim sendo, destacam-se algumas características básicas de RNA:

- *Aprendizado* – As RNA aprendem por experiência, não havendo desta maneira necessidade de explicitar os algoritmos para executar uma determinada tarefa;
- *Associação* – As RNA são capazes de fazer associações entre padrões diferentes devido a utilização de memória distribuída;
- *Generalização* – As RNA são capazes de generalizar seu conhecimento a partir de exemplos anteriores;
- *Abstração* – As RNA são capazes de abstrair a essência de um determinado conjunto de entrada (treinamento), isto é, a partir de padrões ruidosos, extrair a informação do padrão sem ruído;
- *Robustez e Degradação Gradual* – As RNA não sofrem danos abruptos quando por algum motivo há a perda de um conjunto de elementos processadores.

Observa-se que as características básicas de RNA são bastante similares as características de funcionamento do cérebro humano e dos elementos processadores que os compõem como será visto na próxima secção.

3.3. Neurônios Biológicos

O cérebro humano contém aproximadamente 10^{11} células nervosas elementares chamadas de neurônios^[15, 20, 21]. Os neurônios foram identificados anatômicamente pelo neurologista espanhol Ramón y Cajal^[20,21] no século XIX. Como qualquer célula biológica, o neurônio é formado por uma fina membrana celular que reveste toda a célula, que além de sua função biológica normal, também, possui propriedades elétricas importantes para o funcionamento do sistema nervoso central, pois são essenciais para a capacidade de processar e transportar sinais (informações).

Cada um destes neurônios possui conexão sináptica com aproximadamente 10^4 outros neurônios, desta forma estima-se que o cérebro humano possui 10^{15} conexões sinápticas.

Existem vários tipos de neurônios, cada qual com uma determinada função, forma e localização específica, porém os componentes principais de um neurônio são sempre os mesmos.

No neurônio (ver Figura 9 e Figura 10) são identificados três partes que tem funções distintas^[21]:

- *Corpo celular ou Soma* – A parte que contém o núcleo da célula e o citoplasma. Entretanto sua dimensão, forma e localização depende do tipo de neurônio (sensor, motor, local, etc) podendo ter diâmetro de $\sim 50\mu\text{m}$;
- *Axônio* – Em geral os neurônios possuem um único axônio que se caracteriza como uma projeção filamental de diâmetro mais ou menos uniforme e que se estende por distâncias desde alguns centenas de microns até a alguns metros e possui diâmetro entre 0,2 a $20\mu\text{m}$. A função básica do axônio é de transmitir informações na forma de pulsos elétricos regenerativos, isto é, sem atenuação do sinal, para as várias partes do sistema nervoso e do organismo. A velocidade de propagação do sinal que é transmitido pelo axônio varia entre 0,5 a 130 m/s, dependendo do diâmetro do axônio e da existência ou não da bainha de mielina, substância que funciona como material isolante presente nos axônios de neurônios responsáveis por transmitir os sinais vitais do organismo;
- *Árvore Dendrital* - Que são prolongamentos filamentosos que formam ramificações semelhantes aos galhos de árvores, estes galhos são chamados de dendritos. O dendritos são a parte receptora de sinais do neurônio, sua característica mais importante é oferecer uma ampla área de contato para a recepção de informação, estes contatos ocorrem através de estruturas conhecidas com *sinápses*.

Na sinápsse distinguem-se duas partes, a parte anterior composta pela membrana de um axônio pelo qual chega o pulso nervoso, chamado de membrana pré-sináptica e a parte posterior composta pela membrana do dendrito, chamada de membrana pós-sináptica que receberá a informação. Estas duas partes pré e pós-sinápticas são separadas por uma fenda sináptica.




Fig. 9 - Representação das partes que compõem um neurônio biológico^[17]




Fig. 10 – Fotografia colorida artificialmente mostrando neurônios biológicos

O contato entre as membranas através da fenda sináptica é realizado pelos neurotransmissores liberados pela membrana pré-sináptica após a propagação de um impulso nervoso pelo axônio (ver Figura 11, microfotografia colorida artificialmente mostrando um neurônio e suas conexões sinápticas).




Fig. 11 – Fotografia colorida artificialmente mostrando um neurônio biológico e suas sinápses (pontos brilhantes na figura)

Dependendo do tipo de neurotransmissor predominante na sinápsse, o potencial da membrana do dendrito é aumentado (sinápsse excitatória) ou diminuído (sinápsse inibitória). Estes sinais recebidos pelos dendritos de vários neurônios são propagados até o corpo do neurônio, onde são aproximadamente somados. Se esta soma de sinais, dentro de um pequeno intervalo de tempo, for acima de um determinado limite do corpo do neurônio, o mesmo gera um potencial de ação que é então transmitido pelo axônio aos outros neurônios.

Devido a complexidade do sistema nervoso biológico, sempre há o interesse de se comparar o desempenho dos sistemas biológicos (cérebro humano) com os sistemas artificiais de processamento (computador digital), ver Figura 12.

O cérebro humano pode ser interpretado como sendo um processador analógico flexível, e com capacidade de memória muito elevada, o qual vem sendo otimizado pelo processo de evolução natural, através de milhões de anos para executar tarefas importantes para a sobrevivência da espécie^[15]. Observa-se que quanto maior for a importância de uma determinada tarefa para a sobrevivência da espécie, maior será a otimização desta característica física. O sistema nervoso central humano é um exemplo deste fato e foi apresentado por Winston em 1989^[15] da seguinte forma:

- Para realização de operações aritméticas, um cérebro tem uma fração do poder de processamento de uma calculadora de bolso antiga;
- Se considerar o problema da visão, um cérebro tem o poder de processamento de milhões de super computadores;

- Em termos de memorização de fatos arbitrários, o cérebro é muito pior do que um computador digital;
- Entretanto se for considerada a memória associativa para acontecimentos do mundo real, tal como, lembrar o nome de uma pessoa dado uma descrição parcial e ainda com pistas falsas, o cérebro humano é muito superior ao computador digital, que ao invés de utilizar endereçamento por conteúdo utiliza endereço de memória.




Fig. 12 – Comparação entre tarefas biológicas simples versus o poder de processamento digital de 1988^[22]

Assim sendo, as principais diferenças do modo de processamento de informação entre o computador digital e o cérebro humano podem ser observadas na Tabela 1, segundo a proposta de Simpson em 1990^[15,23].

Tabela 1 – Comparação entre o cérebro humano e o computador digital

	Computador digital	Cérebro humano
Velocidade de processamento	nanossegundos	milissegundos
Modo de processamento	serial	paralelo
Processadores	poucos processadores	muitos processadores
Número de processadores e sua complexidade	muitos e complexos	poucos e simples
Armazenamento de conhecimento	memória localizada	memória distribuída
Tolerância a danos	degradação abrupta	degradação suave
Controle do processamento	organizado-sequencial	anárquico-aleatório

3.4. Neurônios Artificiais (Matemático)

O neurônio artificial é a representação matemática do neurônio biológico, uma vez que as funções básicas do neurônio artificial são apenas o modelamento matemático do funcionamento do processo de transmissão, processamento e recepção de sinais em um neurônio biológico.

A representação esquemática do neurônio artificial é baseado também na forma física de um neurônio biológico, como pode ser visto na Figura 13.




Fig. 13 – Representação de um neurônio artificial e sua equivalência com o neurônio biológico

No início do estudo de RNA, mais precisamente na década de 40, surgiu o primeiro modelo matemático para o neurônio artificial, inspirados nos recentes resultados científicos obtidos nesta mesma época por Alan Turing e John von Neumann^[20] que indicavam ser booleana a natureza da inteligência. O neurônio binário (booleano) do neurofisiologista Warren McCulloch e do matemático Walter Pitts no ano de 1943^[24], era extremamente simples, como pode ser observado na Figura 14.




Fig. 14 – O primeiro neurônio artificial

Em 1949, Donald Hebb^[25] um biólogo que estudava o comportamento de animais, propôs um princípio pelo qual o aprendizado em sistemas nervosos complexos poderia ser reduzido a um processo puramente local, em que a intensidade das conexões sinápticas são alteradas apenas em função dos erros detectados localmente, ou seja, no processo de aprendizagem do cérebro humano, quando um axônio de um neurônio está suficientemente próximo para excitar outro neurônio e repetidamente este colabora com o disparo, ocorre um processo de crescimento ou mudança metabólica em um ou em ambos os neurônios de tal forma que a influência do primeiro neurônio para disparar o segundo fica aumentada (modificação dos pesos sinápticos).

No final da década de 50, mais precisamente 1957, Frank Rosenblatt^[26] continuando o estudo de McCulloch e Pitts, criou uma rede de múltiplos neurônios do tipo discriminadores lineares e deu o nome de *Perceptron*. A aparência de uma rede de perceptrons é a mesma utilizada atualmente, composta por uma camada de neurônios de entrada, uma ou mais camadas intermediárias de neurônios (camada escondida) e uma camada de neurônios de saída. O perceptron chamado MARK1 era composto por 400 fotocélulas colocadas em forma de uma matriz quadrada de 20x20 pixels, utilizada como vetor de entrada para o sistema de reconhecimento de caracteres. Os ganhos (pesos) do sistema eram ajustados em um banco de potenciômetros controlados por pequenos motores elétricos.

Em 1960, Bernard Widrow^[27] desenvolveu um modelo neural linear o qual foi chamado de ADALINE (ADAptative LINEar Element) e depois com a sua generalização passou a se chamar MADALINE (Múltipla ADALINE). A grande contribuição de Widrow foi a invenção do princípio de treinamento de redes conhecido como a Regra Delta.

Em 1969, um livro chamado *Perceptron*, escrito por Mavin Minsky e Seymour Papert^[28], mostravam que as redes perceptrons não eram capazes de resolver problemas simples, como o caso da operação booleana do ou exclusivo, além de alegarem que as redes neurais utilizavam processos de aproximações empíricas. Estes fatos abalaram a pesquisa em RNA e foi somente na década de 80 que as pesquisas voltaram a ganhar força.

A Regra Delta Generalizada foi utilizada no algoritmo *Back-Propagation* de Rumelhart, Hinton e Williams em 1986^[29], que foi desenvolvido para redes de neurônios com função de ativação semilineares e superaram os problemas ocorridos com os perceptrons.

Como pode ser observado na Figura 15, o neurônio artificial possui elementos básicos para seu funcionamento. Entre estes elementos destacam-se:

- Estado de Ativação $\Leftrightarrow y_j$;
- Conexão entre processadores (pesos sinápticos) $\Leftrightarrow w_{ij}$;
- Função de Ativação $\Leftrightarrow y_j = F(\text{net}_j)$.




Fig.15 – Representação esquemática de um neurônio artificial

A função de um neurônio, quer seja artificial ou biológico, é depois de acumulado o valor somado dos produtos entre as entradas e os pesos, comparar este valor com o limiar (valor estipulado), e, se este valor é atingindo, o potencial de ação, é transmitido como sinal de saída.

A função de ativação é quem define o sinal de saída do neurônio artificial, se o valor de ativação estiver abaixo de um valor mínimo não produzirá uma saída. Na Figura 16, pode ser observado os tipos mais utilizados para funções de ativação para RNA.




Fig. 16 – Tipos de função de ativação para neurônios artificiais

3.5. Aprendizado e Treinamento de RNA

O processo de aprendizado acontece, basicamente, de duas formas: aprendizado supervisionado (com tutor) e aprendizado não-supervisionado (sem tutor):

- **Aprendizado Supervisionado** - No aprendizado supervisionado, a rede neural é treinada com o auxílio de um tutor. Para tanto, a rede deverá possuir pares de entrada e saída, ou seja, um conjunto de entradas e um conjunto com as saídas desejadas para cada entrada. Toda vez que for apresentada à rede uma entrada, deverá ser verificado se a saída obtida (gerada a partir dos cálculos efetuados com os pesos que a rede possui) confere com a saída desejada para aquela entrada. Sendo diferente, a rede deverá ajustar os pesos da rede de forma que armazene o conhecimento desejado. Essa iteratividade do treino deverá ser repetida com todo o conjunto de treinamento (entradas e saídas), até que a taxa de acerto esteja dentro de uma faixa considerada satisfatória. Essa forma de aprendizado é bem conhecida e tem demonstrado excelentes resultados em aplicações reais, ver Figura 17.




Fig. 17 – Aprendizado Supervisionado

- **Aprendizado Não-Supervisionado** - Este tipo de aprendizado também é conhecido como aprendizado auto-supervisionado. Esse aprendizado não requer saídas desejadas, e por isso é conhecido pelo fato de não precisar usar "tutores" para o seu treinamento. Para o treinamento da rede, são usados apenas os valores de entrada. A rede trabalha essas entradas e se organiza de modo que acabe classificando-as, usando, para isso, os seus próprios critérios. Esse tipo de rede utiliza os neurônios como classificadores, e os dados de entrada, como os elementos para classificação. O processo de classificação

fica por conta da rede neural e o seu algoritmo de aprendizado. A auto-organização demonstrada em redes neurais não-supervisionadas, envolve, o processo de competição e o processo de cooperação entre os neurônios da rede. Muitos pesquisadores têm utilizado esse tipo de rede como detector de características, dada a sua capacidade de aprender a discriminar estímulos ocorrendo em partes espacialmente diferentes, ver Figura 18.




Fig. 18 – Aprendizado Não-Supervisionado

O ajuste sináptico é o aprendizado em cada neurônio do fato apresentado, ou seja, cada neurônio, conjuntamente com todos os outros, representa a informação que atravessou pela rede. O ajuste é realizado em função de um cálculo que aponta a quantidade de erro, para então corrigir os pesos de modo que se produza a saída desejada diante da respectiva entrada.

Nenhum neurônio guarda em si todo o conhecimento, mas faz parte de uma malha que retém a informação graças a todos os seus neurônios. O conhecimento dos neurônios reside nos pesos sinápticos.

No processo de treinamento da rede a mesma deve ser treinada com o conjunto inteiro, sendo apresentado às entradas várias vezes o conjunto de treinamento de forma iterativa. Caso a rede seja treinada 100% para um determinado caso de cada vez, isto afetará, negativamente, o processo de conhecimento dos casos aprendidos, ou seja, isto deverá implicar no esquecimento de casos anteriormente apresentados. E assim, quando chegar ao final do conjunto de treinamento, muito provavelmente, a rede já terá se esquecido dos primeiros casos.

Quando um conjunto de entrada é apresentado à rede, esta pode chegar ao valor estipulado em um determinado número de iterações, ou poderá errar nas próximas iterações. Esse fato se deve ao detalhe de que quando a rede comete um erro durante a fase de treinamento, ocorrem mudanças para compensar este erro. Esta compensação poderá interferir com a habilidade da rede para reproduzir o valor estipulado para um

caso anterior. Quando se retorna um caso que a rede já foi treinada e encontrou o valor desejado, pode-se encontrar um valor não válido (erro), devido aos ajustes feitos durante este novo treinamento ou do treinamento dos outros casos. Desta forma, o treinamento é um processo extremamente iterativo, onde, os casos (conjunto de entrada), são apresentados à rede continuamente até que todos os casos, ou, pelo menos, uma razoável porcentagem destes encontrem o valor estipulado.

Exemplo do treinamento iterativo:

- ❶ Apresenta-se um caso a rede;
- ❷ Conferir o resultado e ajustar os pesos se necessário;
- ❸ Se não for o final do conjunto de treinamento, voltar ao passo ❶;
- ❹ Se, terminado o conjunto de treinamento, e a rede ainda não estiver treinada de forma satisfatória, reiniciar o processo no passo ❶, mantendo os pesos ajustados até o momento;
- ❺ Se o conjunto de treinamento foi terminado e a rede apresenta valores satisfatórios, esta pode ser considerada treinada.

Cada vez que for apresentado para a rede um novo caso, a rede ajustará alguns pesos sinápticos, podendo convergir para um ponto melhor ou não. Insistir no treinamento, algumas vezes, pode não ser uma boa solução, pois a rede já poderá estar treinada da melhor forma possível, e a insistência no treinamento poderá fazer com que todo o conhecimento seja perdido.

Observa-se também que a ordem de entrada dos conjuntos de casos é importante para o treinamento da rede, de forma que, estas entradas devem ser apresentadas a rede sem uma ordem definida, caso contrário isto poderá conduzir a um erro de aprendizado.

3.6. Topologias de RNA

Existem basicamente dois tipos de topologias para RNA, chamadas de *Feedforward* (realimentação para frente) e *Feedback* (realimentação para trás). Uma RNA do tipo *feedforward* os neurônios enviam seus sinais de saída apenas para os neurônios dos quais não recebe nenhuma entrada direta ou indiretamente (via outros neurônios) de forma a não criar laços de realimentação (*loops*). Uma RNA do tipo *feedback* é baseada justamente na possibilidade de formar laços realimentados possibilitando que um neurônio envie sua saída para os neurônios os quais este recebe entradas. Na Figura 19, pode-se observar os esquemas com as topologias de RNA.




Fig. 19 – Topologias de RNA

3.7. Algoritmo de Treinamento *Back-Propagation*

O algoritmo de treinamento *Back-Propagation* (BP) foi criado na década de 80, seu funcionamento é simples e sua topologia pode ser do tipo *feedforward* ou *feedback* com múltiplas camadas.

Durante o processo de treinamento com o algoritmo BP, a rede opera sempre em seqüência de dois passos. No primeiro passo é apresentado um padrão à camada de entrada da rede, e o processo de treinamento é propagado (*feedforward*) através da rede indo de camada em camada até que o padrão seja reproduzido na saída, no segundo passo a saída reproduzida é comparada com a saída desejada (alvo) para este padrão em particular. Se a saída não for satisfatória, é então calculado o erro. O erro é retropropagado (*feed-backward*) no sentido contrário indo da camada de saída para a camada de entrada para ajustar as conexões sinápticas, ver Figura 20 e 21.




Fig. 20 –Funcionamento do algoritmo *Back-Propagation*




Fig. 21 – Fim do treinamento e teste da rede utilizando algoritmo *Back-Propagation*

As redes que utilizam o algoritmo BP trabalham com uma variação da Regra Delta, apropriada para redes de múltiplas camadas chamada de Regra Delta Generalizada^[20]. A Regra Delta padrão implementa um gradiente descendente no quadrado da soma do erro, para as funções de ativação lineares. Em redes sem camadas intermediárias a superfície de erro tem a forma de uma parabolóide com apenas um ponto de mínimo. Entretanto, a superfície de erro pode não ser tão simples, como pode ser visto na Figura 22. A superfície de erro pode ainda ser mais complicada e ter mínimo local, como é mostrado na Figura 23.




Fig. 22 – Superfície de erro de um treinamento com *Back-Propagation*




Fig. 23 – Superfície de erro com mínimo local

Existem várias definições (passos) para a implementação computacional da RNA utilizando o algoritmo BP dentre estes pode-se destacar:

- Regra de propagação ➡ $net_j = \sum x_i \cdot w_{ij} + bias$;
- Função de ativação ➡ não-linear;
- Topologia ➡ *feedforward* ou *feedback* com múltiplas camadas;
- Aprendizado ➡ supervisionado;
- Processo de minimização do erro quadrático pelo método de gradiente descendente ➡

$$\Delta w_{ij} = -\eta \frac{\delta E_j}{\delta w_{ij}};$$

- Peso sináptico i ;
- Neurônio j ;
- Erro quadrático ➡ $E_j = \frac{1}{2}(t_j - y_j)^2$;
- Valor desejado (ALVO) na camada de saída para o neurônio j ➡ t_j ;
- Estado de ativação do neurônio j ➡ y_j ;
- Processo de aprendizagem ➡ $-\Delta w_{ij} = \eta \cdot y_i \cdot e_j$;
- Valor de entrada da conexão sináptica i ➡ y_i ;
- Valor calculado do erro do neurônio j ➡ e_j ;
- Cálculo do erro na camada de saída ➡ $e_j = (t_j - y_j) \cdot \frac{\delta F(net)}{\delta net}$;
- Cálculo do erro na camada intermediária ➡ $e_j = (\sum e_n - w_{jn}) \cdot \frac{\delta F(net)}{\delta net}$

4. Proposta do Sistema de Controle da Posição do Plasma a ser Implementado no Tokamak ETE

4.1. Tokamak ETE (Experimento Tokamak Esférico)

O ETE é uma máquina de concepção avançada, envolvendo aspectos de física e engenharia presentes em poucos dispositivos em operação ou construção no mundo. A configuração de baixa razão de aspecto do ETE possibilita o estudo de plasmas em condições superiores de pressão com bom confinamento, em um dispositivo compacto e de baixo campo magnético, ou seja, de baixo custo. A Figura 24 mostra uma vista artística do tokamak ETE, cujos parâmetros principais são os seguintes:

- ❶ razão de aspecto = 1,5;
- ❷ raio maior = 0,3m;
- ❸ alongação = 1,6 - 1,8;
- ❹ campo magnético toroidal = 0,4T (máximo = 0,8T);
- ❺ corrente de plasma = 200 - 400kA.

Um dos problemas na pesquisa de tokamaks é a determinação da posição e da forma do plasma a cada instante. Esta informação é necessária para comandar os amplificadores de alta potência que irão atuar nas bobinas de controle do equilíbrio e de conformação do plasma. Os sinais de controle devem ser precisos, pois eventualmente limitam a precisão dos laços fechados de retroalimentação. Além disso, a aquisição de dados deve ser rápida, dentro de uma faixa de alguns quilohertz. A dificuldade básica é que muitos dos dados desejados, como, por exemplo, a posição do eixo magnético, não podem ser obtidos diretamente; dependem da operação de diagnósticos sofisticados como o imageamento de raios-X moles emitidos pelo plasma. Um dos diagnósticos mais simples, que fornece também uma maneira rápida e razoavelmente precisa de se inferir a posição e o formato do plasma, é a interpretação de sinais das sondas de campo magnético e das bobinas de fluxo magnético colocadas em volta do plasma. Entretanto, mesmo neste caso, o processo de reconstrução requer a solução do problema não-linear de equilíbrio do plasma. O tempo excessivo de computação envolvido impossibilita a estimativa em tempo real.

As redes neurais artificiais fornecem um novo tratamento do problema intrinsecamente não-linear de extração da configuração do plasma a partir dos

diagnósticos de plasma. Elas apresentam várias características que as tornam também atrativas na área de controle:

- ⇒ Modelamento. Como as redes podem ser treinadas com dados simulados ou reais de um dado sistema, elimina-se a necessidade de desenvolver um modelo detalhado do mesmo.
- ⇒ Sistemas não-lineares. As redes podem representar, com grau arbitrário de precisão, qualquer relação não-linear entre as variáveis do processo.
- ⇒ Sistemas com muitas variáveis. As redes apresentam, naturalmente, um grande número de entradas e saídas, podendo ser facilmente adaptadas a sistemas com muitas variáveis.
- ⇒ Estrutura paralela. A estrutura das redes apresenta alto grau de paralelismo, que conduz ao processamento rápido de informações, bem como tolerância a falhas e ruídos.




Fig.24 – Concepção artística do tokamak ETE

A aplicação as redes neurais artificiais no tokamak ETE^[04] tem, inicialmente, a função de fornecer sinais quase-estacionários para o sistema de controle vertical. O controle dinâmico propriamente dito será realizado por um controlador proporcional

integral-diferenciador (PID) convencional, pressupondo a linearização localizada do sistema.

4.2. Tipo de RNA a ser Implementada no ETE

Existe uma grande variedade de Redes Neurais Artificiais (RNA) em investigação^[18,20,30,31], entretanto para o tokamak ETE deve-se utilizar uma rede conhecida como perceptron de múltiplas camadas ("*Multi Layer Perceptron* - MLP"), que fornece um mapeamento multi-dimensional de um determinado processo. Esta rede aceita um grande número de entradas e fornece uma ou mais saídas cujos valores são funções contínuas dos valores de entrada. A estrutura topológica da rede é de alimentação para frente (*Feedforward*), isto é, as informações processadas não são reutilizadas em partes anteriores do processo. O MLP constitui uma rede de arquitetura simples e vasta utilização na análise e redução de dados, na interpretação de sinais e na tomada de decisões.

O perceptron de múltiplas camadas fornece uma relação matemática contínua explicitamente não-linear entre o vetor de muitas variáveis de entrada, representado por x , e o vetor de muitas variáveis de saída, representado por y . Esta relação constitui um mapeamento M tal que $y = M(x)$. A Figura 25 mostra uma representação esquemática de uma RNA tipo MLP. O vetor de entrada x , de dimensão N_1 , é projetado linearmente por meio de uma matriz W_{12} sobre um vetor intermediário de dimensão arbitrária N_2 . Esta dimensão intermediária, também conhecida como número de unidades de processamento, neurônios ou nós, é a única escolha de projeto na especificação da RNA. O vetor transformado é então submetido a uma função de compressão f aplicada a cada componente vetorial de tal modo que o vetor de saída da camada intermediária é dado por :

$$z = f(W_{12} \cdot x + \theta_2),$$

onde θ_2 é um vetor de deslocamentos ou limiares. A função f mais comumente utilizada é a sigmóide, limitada entre (-1,+1) e definida por: $f(x) = \frac{2}{1 + e^{-x}} - 1$

O vetor z comprimido é então linearmente projetado por meio de uma segunda matriz W_{23} sobre um vetor de dimensão N_3 , que é por sua vez deslocado para fornecer o vetor de saída:

$$y = W_{23} \cdot z + \theta_3$$

A descrição acima corresponde a uma RNA com uma camada escondida (MLP-1); se o vetor de saída é novamente comprimido, linearmente transformado e deslocado para produzir um novo vetor de saída, tem-se uma RNA de duas camadas escondidas (MLP-2), e assim por diante. Portanto, a aproximação MLP-1 do mapeamento M é dada explicitamente por:

$$M(x) = W_{23} \cdot \left(\frac{2}{1 + \exp(-W_{12} \cdot x - \theta_2)} - 1 \right) + \theta_3$$

O expoente vetorial denota uma exponenciação de cada elemento, fornecendo um resultado vetorial. A importância da representação MLP-1, ou de ordem superior, resulta da demonstração que qualquer função contínua e limitada pode ser descrita por um MLP-1 ou MLP-2 sobre um dado volume no espaço dos vetores x ^[32-34]. Os mapeamentos MLP-1, mais simples, tem se mostrado adequados para representar um grande número de processos; em particular, tem sido utilizados na interpretação de diagnósticos e na reconstrução do equilíbrio do plasma de tokamaks.




Fig.25 – Esquema do MLP com uma camada escondida

Desta forma, para escolhas apropriadas dos parâmetros W_{12} , θ_2 , W_{23} e θ_3 o mapeamento M pode aproximar, com precisão arbitrária, qualquer função não-linear de muitas variáveis (sujeito a algumas restrições fracas), desde que a dimensão intermediária N_2 seja suficientemente grande. O treinamento do MLP consiste em determinar-se os pesos W e deslocamentos θ que otimizam a precisão do mapeamento, envolvendo um intenso processo computacional. Uma grande base de dados, formada por mapeamentos exemplificadores do processo, é utilizada neste treinamento. Os

algoritmos de treinamento, de uma forma geral, procuram minimizar a função erro E definida pela raiz quadrada do erro quadrático médio entre o vetor de saída $y(x_n)$ da rede (para um dado vetor de entrada x_n) e o correspondente vetor objetivo y_n , somado sobre todos os exemplos n :

$$E = \left[\frac{1}{N} \sum_{n=1}^N (y(x_n) - y_n)(y(x_n) - y_n) \right]^{\frac{1}{2}}$$

A minimização do erro pode ser atingida por vários métodos, tradicionalmente com a aplicação do algoritmo de retropropagação de erros (*Back-Propagation*)^[29], que é por sua vez baseado no método clássico de otimização por máxima declividade (método de Newton). Como este método lineariza localmente a função erro E , ajustando um plano tangente em cada ponto no espaço de parâmetros W e θ , toda a informação a respeito da função objetivo é perdida, a não ser a inclinação local.

Qualquer que seja o método de otimização utilizado, a base de dados de treinamento deve cobrir todo o espaço de parâmetros de entrada a ser representado pelo mapeamento. As redes neurais artificiais são excelentes para interpolação entre exemplos de treinamento, porém fornecem resultados sofríveis na extrapolação fora da experiência de treinamento. A performance da rede é normalmente avaliada calculando-se o erro para um conjunto teste de exemplos gerado independentemente do conjunto de treinamento. Esta performance pode ser otimizada variando-se a dimensão N_2 da camada escondida.

4.3. Reconstrução do Equilíbrio de Plasma no ETE

A Figura 26 ilustra uma seção reta do tokamak ETE, onde a região pontilhada corresponde à seção reta do plasma. Esta figura ilustra, em particular, um deslocamento vertical Δz da seção do plasma em relação ao plano equatorial. As bobinas poloidais de equilíbrio e de elongação, que tem simetria equatorial, encontram-se indicadas na figura. As sondas de campo magnético e as bobinas de fluxo magnético serão montadas no interior da câmara de vácuo, envolvendo o plasma^[04]. O problema específico de reconstrução magnética consiste em determinar-se os parâmetros geométricos da seção de plasma a partir dos sinais detectados pelas sondas de campo magnético e bobinas de fluxo.




Fig. 26 – Seção reta esquemática do tokamak ETE

Representando por $\mathbf{x}$ o vetor de sinais medidos pelos diagnósticos magnéticos e por $\mathbf{y}$ o vetor de parâmetros de equilíbrio do plasma, quer-se, portanto, determinar o mapeamento $\mathbf{M}$ tal que $\mathbf{y} = \mathbf{M}(\mathbf{x})$. Neste caso, o mapeamento inverso $\mathbf{M}^{-1}$ apresenta uma representação física completa através da equação de Grad-Schlüter-Shafranov para o equilíbrio do plasma. Entretanto, não é possível obter-se uma descrição simples para o mapeamento direto $\mathbf{M}$, sendo em geral necessário recorrer a aproximações. Uma das possibilidades de representação do mapeamento $\mathbf{M}(\mathbf{x})$, que tem apresentado bons resultados, é através de redes neurais artificiais baseadas no MLP [35-36].

Na reconstrução do equilíbrio de um plasma de tokamak normalmente utilizam-se, como bases iniciais de dados para treinamento e teste das redes neurais artificiais, soluções de equilíbrio geradas por programas numéricos que determinam o mapeamento inverso $\mathbf{M}^{-1}$. Estes programas resolvem a equação de Grad-Schlüter-Shafranov, fornecendo os sinais nas sondas magnéticas para cada configuração idealizada do plasma. No caso do tokamak ETE esta sendo formada uma base de dados teórica utilizando o programa de computador TOPEOL [37], desenvolvido no Culham Science Center da Inglaterra (ver exemplo de simulações para o ETE no Apêndice A). No futuro, com a formação de uma base de dados experimentais do ETE, pode-se treinar novamente a rede para operação com configurações mais realistas.

A rede neural artificial treinada para reconstruir o equilíbrio de plasma do ETE será utilizada inicialmente para fornecer os sinais sobre a posição do plasma para um sistema de controle convencional. A Figura 27 mostra esquematicamente a interligação da rede neural com o tokamak ETE. Os sinais de entrada da rede serão fornecidos pelas sondas magnéticas e bobinas de fluxo. Os sinais de saída, exemplificados pelo deslocamento Δz do plasma em relação ao plano equatorial, serão utilizados para alimentar os amplificadores de alta potência através de um controlador proporcional integral-diferenciador. Fechando o laço de controle, as saídas dos amplificadores serão aplicadas em bobinas de controle da posição do plasma, que serão montadas junto às bobinas de equilíbrio vertical indicadas na Figura 26.




Fig.27 – Esquema de interligação da rede neural para o controle vertical do tokamak ETE

Na Figura 27 observa-se o controlador neural, este controlador deverá ser uma RNA do tipo MLP, com topologia *feedforward* e algoritmo de treinamento *Back-Propagation*. Sua função será de reposicionar a coluna de plasma dado o deslocamento Δz . Na Figura 28, tem-se o esquema da RNA sendo treinada com o algoritmo treinamento *Back-Propagation*.

Finalmente, é preciso lembrar que, embora todo o processo de treinamento da rede neural seja realizado em um computador digital, a plena performance da rede e sua utilização em tempo real só é possível através da implementação em circuito híbrido^[14, 36,38]. Os pesos otimizados durante o processo de treinamento deverão ser descarregados

em chips analógicos comerciais, especialmente projetados para uso em redes neurais artificiais, onde serão armazenados usando tecnologia EEPROM. Os chips disponíveis contém 64 ou mais neurônios e o processamento de uma camada de neurônios pode ser realizada em $3\mu s$, com possibilidade de ligação de chips em paralelo.




Fig. 28 – Esquema de treinamento de uma RNA utilizando *Back-Propagation* para controlar a posição da coluna de plasma de um tokamak

4.4. Controle Dinâmico do Plasma no ETE^[39-42]

A grande maioria das aplicações de sistemas de controle por retroalimentação pressupõe o comportamento linear do sistema a ser controlado, ao menos sobre uma região finita do espaço de operação. Esta hipótese é freqüentemente válida mesmo para sistemas não-lineares. Nestes casos a atuação local de controladores proporcionais integral-diferenciadores convencionais fornece bons resultados. Por outro lado, em sistemas mais complicados, intrinsecamente não-lineares ou que operam numa região extensa com grande variação dos parâmetros, possivelmente dependentes do tempo, pode-se muitas vezes manter o formalismo linear com adaptação do sistema de controle. Esta adaptação é feita pela substituição automática do controlador em cada região de operação ou pela programação dos parâmetros de controle.

Uma alternativa para este problema é abrir-se mão da hipótese linear e de todo o formalismo matemático desenvolvido na área de controle tradicional, com grande prejuízo do tratamento teórico. Neste caso, a generalidade proporcionada pela representação MLP para uma função de muitas variáveis torna as redes boas candidatas a controladores não-lineares. A Figura 29 mostra um sistema de controle com um laço simples de retroalimentação, em que o controlador proporcional integral-diferenciador é substituído por uma RNA do tipo MLP.




Fig. 29 – Esquema de um laço simples de controle utilizando um controlador PID linear ou um controlador MLP não-linear. A caixa tracejada é o sistema a ser controlado

É preciso lembrar que no início a RNA tipo MLP tem por finalidade apenas fornecer os sinais quase estacionários sobre a posição do plasma ao controlador PID. Na otimização de um controlador MLP para um processo complexo será necessário, provavelmente, recorrer a uma segunda rede neural que atue como modelo de referência não-linear. Este MLP de referência substitui o conjunto de equações diferenciais que modela o sistema linear no ajuste dos parâmetros de um controlador PID.

Para viabilizar a aplicação do MLP como controlador dinâmico no tokamak ETE será necessário, inicialmente, criar-se uma base de dados experimentais utilizando um sistema de controle convencional. A alternativa para treinamento da rede seria criar um banco de dados obtidos com programas de computador, exemplificados pelo TSC (*Tokamak Simulation Code*), que simulam a evolução dinâmica do plasma de tokamaks. Entretanto, antes de aplicar um MLP ao controle dinâmico do ETE seria interessante testar uma rede do tipo MLP, implementada em circuito, no controle de um sistema não-linear de modelagem mais simples como, por exemplo, um pêndulo não-linear^[39] ou um sistema de levitação magnética^[40].

5. Conclusões e Perspectivas

Este primeiro relatório referente à bolsa de doutorado “Redes Neurais no Modelamento e Controle de Tokamaks – Aplicação ao ETE”, descreve os conceitos básicos sobre Redes Neurais Artificiais (RNA), bem como, as técnicas de implementação, topologias existentes, algoritmos de treinamento, etc., e também, são apresentados alguns tipos de controle de posição da coluna de plasmas em tokamaks, os quais utilizavam outras técnicas de controle. Foi descrito neste relatório, a proposta de utilização de RNA para o controle da posição da coluna de plasma no tokamak ETE, conforme o projeto de pesquisa aprovado pela FAPESP para obtenção de bolsa de doutoramento no país.

Durante este período:

- Foi comprado com a reserva técnica um computador PC Pentium II 400Mhz 128MRAM para auxiliar nas simulações de equilíbrio com o programa TOPEOL e também as simulações de RNA;
- Foi apresentado um seminário sobre Redes Neurais Artificiais e a proposta de aplicação no ETE, ver Apêndice B;
- Foram cursadas matérias para a obtenção de créditos para a tese no Instituto Tecnológico da Aeronáutica (ITA), na departamento de Engenharia Eletrônica e Computação (EEC) na área de Dispositivos e Sistemas Eletrônicos, ver Apêndice C.
- Foi realizado também um levantamento bibliográfico o qual procura atender a solicitação feita pelo acessor no início da bolsa;
- Como pode ser visto no decorrer do relatório também foi realizado um estudo sobre RNA para controle;
- Foi iniciado o estudo do programa cálculo de equilíbrio em tokamaks, TOPEOL para a formação do banco de dados de treinamento;
- O estudante também ajudou na montagem do tokamak ETE no LAP/INPE.

Por ocasião do próximo relatório desta bolsa de pesquisas, espera-se:

- Concluir os cursos no Instituto Tecnológico da Aeronáutica (ITA);
- Modificar o programa TOPEOL incluindo as bobinas de fluxo magnético;
- Formar a base de dados de treinamento e testes com o TOPEOL para simular em computador uma RNA do tipo *feedforward* e algoritmo de treinamento *Back-Propagation*;
- Listar opções de compra para um *hardware* neural.

Referências Bibliográficas

- [01] Barbosa, L.F.W., *Sistema elétrico pulsado com controle digital do tokamak ETE (Experimento Tokamak Esférico)* (Tese de Mestrado) – ITA, São José dos Campos, 1998.
- [02] Del Bosco, E., *Formação do plasma no TBR* (Tese de Mestrado) - IFUSP, São Paulo, 1981.
- [03] Ueta, A.Y., *Campo vertical de equilíbrio no tokamak TBR* (Tese de Mestrado) - IFUSP, São Paulo, 1985.
- [04] Ludwig, G.O., *Projeto de Pesquisa submetido a FAPESP para obtenção de bolsa de doutoramento no país* - INPE, São José dos Campos, 1998.
- [05] Artemenkov, L.I.; Golovin, I.N.; Kozlov, P.I., *Experiments on equilibrium in the uncased TO-1 tokamak device by means of a feedback system*, Nuclear Fusion 12: 27-31, 1972.
- [06] Hugill, J. and Gibson, A., *Servo-control of plasma position in CLEO-tokamak*, Nuclear Fusion 14: 611-619, 1974.
- [07] Anderson, J.L.; Booth, R.S.; Colchin, R.J.; Miskell, R.V.; Bailey, J.M., *Feedback control for plasma equilibrium in ORMAK*, Nuclear Fusion 16: 629-637, 1976.
- [08] Nagayama, Y.; Naito, N.; Ueda, Y.; Ohki, Y.; Miyamoto, K., *Feedback control of vertical plasma position in non-circular tokamak TNT-A*, Nuclear Fusion 24: 1242-1249, 1984.
- [09] Mori, M.; Suzuki, N.; Shoji, T.; Yanagisawa, Y.; Tani, T.; Matsuzaki, Y., *Stability limit of feedback control of vertical plasma position in the JFT-2M tokamak*, Nuclear Fusion 27: 725-734, 1987.
- [10] Ogata, A. and Ninomiya, H.; *Optimal feedback control of plasma parameters in the tokamaks*, Jnp. J. Appl. Phys. 18: 825, 1979.
- [11] Firestone, M., *Analysis of modern optimal control theory applied to plasma position and current control in TFTR*, IEEE Trans. Plasma Sci. PS-10: 105, 1982.
- [12] Kessel, C.E.; Firestone, M.; Conn, R.W., *Linear optimal control of tokamak fusion devices*, Fusion Technology 17: 391-411, 1990.
- [13] Portone, A.; et al., *Dynamic control of plasma position and shape in ITER*, Fusion Technology 32: 347-389, 1997.
- [14] Windsor, C. G.; Todd, T. N.; Trotman, D. L. and Smith, M. E. U., *Real Time Electronic Neural Nets for ITER-like Multiparameter Equilibrium Control in Compass-D*, UKAEA Fusion, Report UKAEA FUS 307, 1995.

- [15] Nascimento Jr, C.L.; Yoneyama, T., *Inteligência artificial em automação e controle*, Versão 3, ITA, São José dos Campos, 1998.
- [16] Marchi, J. e Fabro, J.A., *SNNAP – sistema neural de navegação em ambiente pré-programado*, IV Congresso Brasileiro de Redes Neurais, 118-123, 20-22 julho, São José dos Campos, São Paulo, 1999.
- [17] Schalkoff, R.J., *Artificial Neural Networks*, Mc Graw-Hill, New York, 1997.
- [18] Glessener, M. and Pochmuller, W., *Neurocomputers: Na Overview of Neural Networks in VLSI*, Neural Computer Series, Chapman and Hall, London, 1994.
- [19] Hecht-Nielsen, R., *Neurocomputing*, Addison-Wesley, 1990.
- [20] Kovács, Z.L. *Redes neurais artificiais – fundamentos e aplicações*, Collegium Cognitio, São Paulo, 1996.
- [21] Kovács, Z.L. *O cérebro e sua mente*, Collegium Cognitio, São Paulo, 1997.
- [22] DARPA, Neural Networks Study. AFCEA International Press, 1988.
- [23] Simpson, P.K., *Artificial Neural Systems – Foundations, Paradigms, Applications, and Implementations*, Pergamon Press, London, 1990.
- [24] McCulloch, W. and Pitts, W., *A logical calculus of ideas immanent in nervous activity*, Bulletin of Mathematical Biophysics, 5: 115-133, 1943.
- [25] Hebb, D.O., *The organization of Behavior*, John Wiley and Sons, 1949.
- [26] Rosenblatt, F. *The Perceptron: A probabilistic model for informations storage and organization in the brain*, Psychological Review, 65:386-408, 1958.
- [27] Widrow, B. and Hoff, M.E., *Adaptative Switching Circuits*, Proc. of 1960 WESCON Convention Record, 96-104, 1960.
- [28] Minsky, M. and Papert, S., *Perceptrons: Na introduction to Computational Geometrey*, MIT Press, 1969.
- [29] Rumelhart, D. E.; Hinton, G. E. and Williams, R. J., *Learning Representations by Back-propagation Errors*, Nature 323: 533-536, 1986.
- [30] Lippman, P. R., *An Introduction to Computing with Neural Nets*, IEEE ASSP Magazine 4: 4-22, 1987.
- [31] Beale, R. and Jackson, T., *Neural Computing; an Introduction*, Adam Hilger, London, 1990.

- [32] Cybenko, G., *Approximations by Superpositions of a Sigmoidal Function*, Math. Cont. Signals and Systems 2: 303-314, 1989.
- [33] Hornik, K.; Stinchcombe, M. and White, H., *Multilayer Feedforward Networks are Universal Approximators*, Neural Networks 2: 359-366, 1989.
- [34] Poggio, T. and Girosi, F., *Networks for Approximation and Learning*, Proc. IEEE 78: 1481-1497, 1990.
- [35] Lister, J.B. and Schnurrenberger, H., *Fast Non-Linear Extraction of Plasma Equilibrium Parameters Using a Neural Network Mapping*, Nucl. Fusion 31: 1291, 1991.
- [36] Bishop, C. M.; Cox, P. M.; Haynes, P. S.; Roach, C. M.; Smith, M. E. U.; Todd, T. N. and Trotman, D. L., *A Neural Network Approach to Tokamak Equilibrium Control*, NCM 91: Applications of Neural Networks, Springer-Verlag, 1991.
- [37] Haynes, P. and Buttery, R., *TOPEOLA User's Guide edition 2.0*, UKAEA Fusion, Culham, UK, 1995.
- [38] Lister J. B.; Schnurrenberger H. and Marmillod Ph., *Implementation of a Multi-Layer Perceptron for a Non-linear Control Problem*, Lausanne Report LRP 398/90, 1990.
- [39] Drummond, A.C.; Oliveira, K. C. e Bauchspiess, A., *Estudo do controle de pêndulo inverso sobre carro utilizando rede neural de base radial*, IV Congresso Brasileiro de Redes Neurais, 320-325, 20-22 julho, São José dos Campos, São Paulo, 1999.
- [40] Bleuler, H.; Diez, D.; Lauber, G.; Meyer, U. and Zlatnik, D., *Nonlinear Neural Network Control with Application Example*, Proc. Int. Neural Network Conference, Paris, IEEE, 201, 1990.
- [41] Narendra, K.S. and Parthasarthy, K., *Identification and control of dynamical systems using neural networks*, IEEE trans., 1:1-27, 1990.
- [42] Narendra, K.S., *Neural networks for control: Theory and practice*, Proc. of IEEE, 84(10): 1385-1406, October, 1996.

APÊNDICE A

Simulações iniciais com o programa de cálculo de equilíbrio de colunas de plasma em tokamaks TOPEOL





Estas páginas de simulações do TOPEOL, mostram o equilíbrio do plasma no tokamak ETE para diferentes níveis de corrente elétrica circulando nas bobinas de campo vertical. Observa-se que ao fazer fluir mais corrente elétrica (desequilibrada entre as bobinas) em um dos pares de bobinas verticais, há uma modificação na posição do plasma, de forma que ao introduzir sondas no programa TOPEOL, pode-se obter valores de fluxo magnético, dada uma perturbação proposital no equilíbrio do plasma no ETE.

Nestas figuras observa-se a deformação da coluna do plasma e a relação do eixo geométrico da câmara de vácuo (Z_0) com o eixo magnético do plasma (Z), destacado em vermelho nas figuras A, C e E. E também, são observados os valores de corrente elétrica nas bobinas de campo vertical, destacadas em vermelho nas figuras B, D e F.

- **Fig.A e Fig.B** – Coluna de plasma em equilíbrio;
- **Fig.C e Fig.D** – Coluna desequilibrada com o eixo magnético derivando para $Z+$ (mais);
- **Fig.E e Fig.F** - Coluna desequilibrada com o eixo magnético derivando para $Z-$ (menos).

*** Graphical output test ***

Poloidal flux contours




Device General:
Limiter-bound equilibrium

Penetration	1.1360
Penetration	1.1277
Plasma Current	0.2000 MA
Toroidal Field Current	0.6300 MA
Toroidal Field at axis	0.3864 T
Toroidal Field at Plane	0.4238 T
R	0.2973 m
Z	-1.9422E-16 m
a	0.1935 m
R/a	1.5368
elongation	1.5802
elongation at q95	1.5662
elongation at axis	1.3462
elongation function	2.7482E+06
Triang. (1)	0.2632
Triang. (2)	0.2761
Plasma area	0.1958 m ²
Plasma vol.	0.3257 m ³
Ro	0.3261 m
Zc	0.0000
PSI at axis per rev	-5.9294E-03 Vs
PSI at boundary per rev	-0.0503 Vs
External Inductance	1.2283E-07
qo	1.1261
q edge	5.8808
q (95)	4.7279
q*	2.4661
q*95	5.5410
Jo	1.9840 MA/m ²
Diagnostic flux	2.7447E-03 Vs
Bv (Shafranov)	0.1175 T
Line Integral Pressure	1.9546E+03 Pa m
Vol. Int. Pressure	1.2494E+03 Pa m ³
Vol. average Pressure	3.8363E+03 Pa m ³
Pressure at magnetic a	7.9100E+03 Pa
Thermal Energy	1.9744E+03 J
Base on avg axis	0.1028 m
Minimum Radius	0.1039 m
Maximum Radius	0.4908 m
min Z	-0.3057 m
max Z	0.3057 m
Vol. Int. Bt**2	0.0795 T m ³
Vol. average Bt**2	0.2440 T m ³
Vol. Int. vacuum Bt**2	0.0000 T m ³
Vol. Int. Bp**2	5.8956E-03 T m ³
Vol. average Bp**2	0.0181 T m ³
Toroidal flux	0.0974 Vs
Vacuum Tor Flux	0.0947 Vs
Beta (1)	0.0281
Beta (2)	0.0395
Beta (3)	0.0368
Beta (4)	0.0537
g (2)	1.5079
Beta-P (1)	0.3317
Beta-P (2)	0.5327
Beta-P (4)	0.3553
L1 (1)	0.7052
L1 (2)	0.7227
L1 (3)	0.6278
Beta-P (3) L1 (2)/2	0.7463
Line Integral equation	0.2347 m
Line BetaP + L1/2	0.6878
L1/2	0.3455
BETAP	1.5162
Int. toroidal Mag. En	3.1621E+04 J
Int. poloidal Mag. En	2.3455E+03 J
Int Pol. E due to plus	3.5321E+03 J
Int Pol. E due to plus	5.9897E+03 J
Poloidal Magnetic En	4.0482E+04 J
Int. (for E-His Tor E)	1.7928E+03 J
Total Reg. E - Vacuum	4.2477E+04 J
Total Thermal and Magn	4.2477E+04 J
By (Shafranov)	0.1175

topeol2.35 run at on by L.F.W.Barbosa - ETE/LAP/INPE

*** Graphical output test ***

COIL	R/M	Z/M	DR/M	OZ/M	I/A	TURNS	BLK	CCT
1	0.1025	0.7070	0.0210	0.1000	-1.400000+04	20	1	1
2	0.1025	-0.7070	0.0210	0.1000	-1.400000+04	20	2	2
3	0.6500	0.8710	0.0100	0.0200	-2.800000+04	1	3	3
4	0.6500	-0.8710	0.0100	0.0200	-2.800000+04	1	4	4
5	0.7000	0.3700	0.0400	0.0400	-9.000000+04	1	5	5
6	0.7000	-0.3700	0.0400	0.0400	-9.000000+04	1	6	6
7	0.2000	0.8000	0.0400	0.0400	1.600000+05	1	7	7
8	0.2000	-0.8000	0.0400	0.0400	1.600000+05	1	8	8
9	0.0725	0.0000	0.0210	1.3000	-1.400000+04	260	9	9





Summary of the problem	
BETAI	= 0.2800
RMAJOR	= 0.3500
RMINOR	= 0.2550
HEIGHT	= 0.6000
NR	= 65.0000
NZ	= 65.0000
HR	= 7.9687E-03
HZ	= 0.0188
BZVERT	= 0.0000
BZERO	= 0.3600
profile type	= 6.0000
TORCUR	= 2.0000E+05
A	= 2.2864
B	= 0.5000
C	= 1.0000
D	= 0.0000
E	= 0.0000
ICURNT	= 1.0000
NSTEPS	= 100.0000
EPS	= 4.0000E-06
ITMAX	= 10.0000
ERRMAX	= 1.0000E-04
NOIT	= 1.0000
BZVERT	= 0.0000
XP	= 0.1000
YP	= 0.1300
RP	= 2.0000E-03
HP	= 0.0000

topeol_2.35 run at on by L.F.W.Barbosa - ETE/LAP/INPE

*** Graphical output test ***

Poloidal flux contours




Device: General
Limiter-bound equilibrium

Parasignation	1.1337	
Parasignation	1.1257	
Plasma Current	0.2000	MA
Toroidal Field Current	0.6300	MA
Toroidal Field at magn	0.3888	T
Toroidal Field at Plas	0.4272	T
R	0.2950	m
Z	0.0629	m
a	0.1912	m
R/a	1.5429	
elongation	1.6207	
elongation at q95	1.6006	
elongation at axis	1.4374	
elongation function	2.8644E+06	
Triang. (1)	0.2400	
Triang. (2)	0.2497	
Plasma area	0.1861	m^2
Plasma vol.	0.3233	m^3
Ro	0.3241	m
Zo	0.0433	m
PSI at axis per rev	-4.5831E-03	Vb
PSI at boundary per rev	-0.0503	Vb
External Inductance	1.2084E-07	
q0	1.1032	
q edge	5.7103	
q (95%)	4.6742	
q*95	2.5041	
Jo	5.5743	
Jo	2.0031	MA/m^2
Diamagnetic flux	2.7012E-03	Vb
Bv (Shafranov)	0.1186	T
Line Integral Pressure	1.9057E+03	Pa m
Vol. Int. Pressure	1.2322E+03	P.m^3
Vol. average Pressure	3.8134E+03	P.m^3
Pressure at magnetic a	7.8817E+03	Pa
Thermal Energy	1.8692E+03	J
Beta on axis	0.1016	
Minimum Radius	0.1039	m
Maximum Radius	0.4862	m
min Z	-0.2470	m
max Z	0.3727	m
Vol. Int. Bt**2	0.0798	T.m^3
Vol. average Bt**2	0.2467	T.m^3
Vol. Int. vacuum Bt**2	0.0000	T.m^3
Vol. Int. Bp**2	5.8215E-03	T.m^3
Vol. average Bp**2	0.0180	T.m^3
Toroidal flux	0.0978	Vb
Vacuum Tor flux	0.0951	Vb
Beta (1)	0.0278	
Beta (2)	0.0368	
Beta (3)	0.0342	
Beta (4)	0.0525	
g (3)	1.4783	
Beta-P (1)	0.3297	
Beta-P (2)	0.5322	
Beta-P (4)	0.3510	
Li (1)	0.7114	
Li (2)	0.7255	
Li (3)	0.6249	
BetaP (3) - Li (2) / 2	0.7489	
Lao integral equation	0.2231	m
Lao BETAp + Li/2	0.6860	
Li/2	0.3474	
BETAp	1.5155	
Int. toroidal Mag. Enr	3.1733E+04	J
Int. poloidal Mag. Enr	2.3163E+03	J
Int. Pol. E due to plas	3.4970E+03	J
Tot Pol. E due to plas	5.9138E+03	J
Poloidal Magnetic Enr	4.0707E+04	J
Int. (for E-Vac Tor E)	1.7454E+03	J
Total Mag. E - Vacuum	4.2471E+04	J
Total Thermal and Magn	4.4320E+04	J
Bv (Shafranov)	0.1185	T

topeol_2.35 run at on by L.F.W.Barbosa - ETE/LAP/INPE

*** Graphical output test ***

COIL	R/M	Z/M	DR/M	DZ/M	I/A	TURNS	BLK	CCT
1	0.1025	0.7070	0.0210	0.1000	-1.400000+04	20	1	1
2	0.1025	-0.7070	0.0210	0.1000	-1.400000+04	20	2	2
3	0.6500	0.8710	0.0100	0.0200	-2.800000+04	1	3	3
4	0.6500	-0.8710	0.0100	0.0200	-2.800000+04	1	4	4
5	0.7000	0.3700	0.0400	0.0400	-8.980000+04	1	5	5
6	0.7000	-0.3700	0.0400	0.0400	-9.020000+04	1	6	6
7	0.2000	0.8000	0.0400	0.0400	1.600000+05	1	7	7
8	0.2000	-0.8000	0.0400	0.0400	1.600000+05	1	8	8
9	0.0725	0.0000	0.0210	1.3000	-1.400000+04	260	9	9




Summary of the problem	
BETAI	= 0.2800
RMAJOR	= 0.3500
RMINOR	= 0.2550
HEIGHT	= 0.6000
NR	= 65.0000
NZ	= 65.0000
HR	= 7.9687E-03
HZ	= 0.0188
BZVERT	= 0.0000
BZERO	= 0.3600
profile type	= 6.0000
TORCUR	= 2.0000E+05
A	= 2.2989
B	= 0.5000
C	= 1.0000
D	= 0.0000
E	= 0.0000
ICURNT	= 1.0000
NSTEPS	= 100.0000
EPS	= 4.0000E-06
ITMAX	= 10.0000
ERRMAX	= 1.0000E-04
NOIT	= 1.0000
BZVERT	= 0.0000
XP	= 0.1000
YP	= 0.1300
RP	= 2.0000E-03
HP	= 0.0000


toped_2.35 run at on by L.F.W.Barbosa - ETE/LAP/INPE

*** Graphical output test ***


Poloidal flux contours




q versus radius



J versus radius



P versus radius



Device: General:


Limiter-bound equilibrium

Parasignation	1.1337
Parasignation	1.1257
Plasma Current	0.2000 MA
Toroidal Field Current	0.6200 MA
Toroidal Field at edge	0.3888 T
Toroidal Field at Plac	0.4271 T
R	0.2950 m
Z	-0.0029 m
a	0.1913 m
R/a	1.5431
elongation	1.6208
elongation at q95	1.6009
elongation at axis	1.4153
elongation function	2.8651E+06
Triang. (1)	0.2400
Triang. (2)	0.2497
Plasma area	0.1861 m^2
Plasma vol.	0.3233 m^3
Ra	0.3241 m
Za	-0.0433 m
PSI at axis per rev	-6.5851E-03 Wb
PSI at boundary per rev	-0.0503 Wb
External Inductance	1.2084E-07
q0	1.1032
q edge	5.7103
q (95%)	4.6742
q*	2.5042
q*95	5.5733
Jo	2.0015 MA/m^2
Diamagnetic flux	2.7012E-03 Wb
Bv (Shafranov)	0.1186 T
Line Integral Pressure	1.9057E+03 Pa m
Vol. Int. Pressure	1.2328E+03 Pa m^3
Vol. average Pressure	3.8134E+03 Pa m^3
Pressure at magnetic a	7.8817E+03 Pa
Thermal Energy	1.8492E+03 J
Beta on mag axis	0.1016
Minimum Radius	0.1038 m
Maximum Radius	0.4861 m
min Z	-0.3727 m
max Z	0.2470 m
Vol. Int. Beta2	0.0798 T.m^3
Vol. average Beta2	0.2467 T.m^3
Vol. Int. vacuum Beta2	0.0000 T.m^3
Vol. Int. Beta2	5.8215E-03 T.m^3
Vol. average Beta2	0.0180 T.m^3
Toroidal flux	0.0978 Wb
Vacuum Tor flux	0.0951 Wb
Beta (1)	0.0278
Beta (2)	0.0388
Beta (3)	0.0362
Beta (4)	0.0525
g (2)	1.4762
Beta-P (1)	0.3297
Beta-P (2)	0.5322
Beta-P (4)	0.3510
Li (1)	0.7114
Li (2)	0.7255
Li (3)	0.6249
BetaP (3)+Li (2)/2	0.7489
Leo Integral equation	0.2351 m
Leo, BETAp + Li/2	0.6880
Li/2	0.3474
BETAp	1.5155
Int. toroidal Mag. Ene	3.1733E+04 J
Int. poloidal Mag. Ene	2.3163E+03 J
Int Pol. E due to plas	3.4970E+03 J
Tot Pol. E due to plas	5.9138E+03 J
Poloidal Magnetic Ene	4.0707E+04 J
Int. (Tor E-Vac Tor E)	1.7634E+03 J
Total Mag. E - Vacuum	4.2471E+04 J
Total Thermal and Magn	4.4320E+04 J
Bv (Shafranov)	0.1186 T

topeol_2.35 run at on by L.F.W.Barbosa - ETE/LAP/INPE

*** Graphical output test ***

COIL	R/M	Z/M	DR/M	DZ/M	I/A	TURNS	BLK	CCT
1	0.1025	0.7070	0.0210	0.1000	-1.400000E+04	20	1	1
2	0.1025	-0.7070	0.0210	0.1000	-1.400000E+04	20	2	2
3	0.6500	0.8710	0.0100	0.0200	-2.800000E+04	1	3	3
4	0.6500	-0.8710	0.0100	0.0200	-2.800000E+04	1	4	4
5	0.7000	0.3700	0.0400	0.0400	-9.020000E+04	1	5	5
6	0.7000	-0.3700	0.0400	0.0400	-8.980000E+04	1	6	6
7	0.2000	0.8000	0.0400	0.0400	1.600000E+05	1	7	7
8	0.2000	-0.8000	0.0400	0.0400	1.600000E+05	1	8	8
9	0.0725	0.0000	0.0210	1.3000	-1.400000E+04	240	9	9



Summary of the problem	
BETAI	= 0.2800
RMAJOR	= 0.3500
RMINOR	= 0.2550
HEIGHT	= 0.6000
NR	= 65.0000
NZ	= 65.0000
HR	= 7.9687E-03
HZ	= 0.0188
BZVERT	= 0.0000
BZERO	= 0.3600
profile type	= 6.0000
TORCUR	= 2.0000E+05
A	= 2.2989
B	= 0.5000
C	= 1.0000
D	= 0.0000
E	= 0.0000
ICURNT	= 1.0000
NSTEPS	= 100.0000
EPS	= 4.0000E-06
ITMAX	= 10.0000
ERRMAX	= 1.0000E-04
NOIT	= 1.0000
BZVERT	= 0.0000
XP	= 0.1000
YP	= 0.1300
RP	= 2.0000E-03
HP	= 0.0000

APÊNDICE B

Redes Neurais Artificiais e a Proposta de Utilização desta Técnica no Controle do Plasma no ETE

Luis Filipe de F.P.W. Barbosa

INPE
São José dos Campos
Setembro 1999

1. Introdução

- Economia tempo na execução de tarefas;
- A própria evolução humana;
- A necessidade de criar máquinas inteligentes;
- Técnicas de Inteligência Artificiais:
 - Sistemas Especialistas;
 - Lógica Nebulosa;
 - Redes Neurais Artificiais.


Sumário

- ① Introdução;
- ② Redes Neurais Artificiais;
- ③ Neurônio Biológico;
- ④ Neurônio Artificial;
- ⑤ Aprendizado e Treinamento;
- ⑥ Topologias de Redes;
- ⑦ Alguns Algoritmos de Treinamento;
- ⑧ Algoritmo Back-Propagation;
- ⑨ Proposta para o ETE;
- ⑩ Próxima Etapa.

2. Redes Neurais Artificiais (RNA)




Um das definições de Redes Neurais Artificiais:

“São sistemas inspirados no sistema nervoso biológico, mais precisamente na estrutura do elemento processador deste sistema, o **NEURÔNIO**. Estes sistemas tem modo de processamento paralelo, são capazes de adquirir, armazenar e utilizar o conhecimento experimental”.



[Glessener 1994]

3. Neurônio Biológico




- O cérebro humano possui **~10 bilhões** neurônios;
- Cada neurônio tem **~1.000 a 10.000** conexões sinápticas
- Um cérebro possui então **~60 trilhões** de conexões sinápticas;
- Uma pessoa em um dia de descanso chega a fazer **~8 milhões** de conexões sinápticas (~100 conexões a cada segundo);
- Nos primeiros anos de vida **~1 milhão** de sinapses são formadas por segundo!

Cérebro Humano X Computador Digital



	<i>Computador digital</i>	<i>Cérebro humano</i>
Velocidade de processamento	nanossegundos	milissegundos
Modo de processamento	serial	paralelo
Processadores	poucos processadores	muitos processadores
Complexidade dos processadores	complexos	simples
Armazenamento de conhecimento	memória localizada	memória distribuída
Tolerância a danos	degradação abrupta	degradação suave
Controle do processamento	organizado-seqüencial	anárquico-aleatório

[Simpson 1996]




[DARPA 1988]

4. Neurônio Artificial (Matemático)



Evolução Histórica


- **1943** – Warren McCulloch e Walter Pitts
- **1949** – Donald Hebb
- **1957** – Frank Rosenblatt
- **1960** – Bernard Widrow
- **1969** – M. Minsky e S. Papert
- **1986** – Rumelhart, Hinton e Williams



$$y^{k+1} = \begin{cases} 1 & \text{se } \sum_{i=1}^n w_i x_i^k \geq T \\ 0 & \text{se } \sum_{i=1}^n w_i x_i^k < T \end{cases}$$






Neurônio Artificial



Estado de ativação ➡ y_j

Conexão entre processadores (pesos sinápticos) ➡ w_{ij}


Função de ativação ➡ $y_j = F(\text{net}_j)$



5. Aprendizado e Treinamento

Se divide em dois processos de ajuste sinápticos:

- **APRENDIZADO SUPERVISIONADO**




- **APRENDIZADO NÃO SUPERVISIONADO**



- O conhecimento da rede é distribuído nos pesos sinápticos (w_{ij});
- A rede não deve ser treinada 100% para um dado caso e o treinamento não deve ser ordenado.

6. Topologias de Redes Neurais Artificiais



7. Alguns Algoritmos de Treinamento de RNA

- Regra de Hebb;
- Perceptron;
- Back-Propagation;
- Hopfield;
- Kohonen;
- Etc...

8. Algoritmo Back-Propagation

- Atualiza os pesos das camadas intermediárias, ou seja, os erros são retro-propagados da camada de saída até a camada de entrada;
- Regra de propagação $\Rightarrow \text{net}_j = \sum x_i \cdot w_{ij} + \text{bias}$;
- Função de ativação $\Rightarrow$ não-linear;
- Topologia $\Rightarrow$ feedforward ou feedback com múltiplas camadas MLP;
- Aprendizado $\Rightarrow$ supervisionado;
- Processo de minimização do erro quadrático pelo método de gradiente descendente $\Rightarrow$






$$\Delta w_{ij} = -\eta \frac{\delta E_j}{\delta w_{ij}};$$

- Peso sináptico i ;
- Neurônio j ;
- Erro quadrático $E_j = \frac{1}{2}(t_j - y_j)^2$;
- Valor desejado (ALVO) na camada de saída para o neurônio $j \Rightarrow t_j$;
- Estado de ativação do neurônio $j \Rightarrow y_j$;
- Processo de aprendizagem $\Rightarrow -\Delta w_{ij} = \eta \cdot y_i \cdot e_j$;
- Valor de entrada da conexão sináptica $i \Rightarrow y_i$;
- Valor calculado do erro do neurônio $j \Rightarrow e_j$;
- Cálculo do erro na camada de saída $\Rightarrow e_j = (t_j - y_j) \cdot \frac{\delta F(\text{net})}{\delta \text{net}}$;
- Cálculo do erro na camada intermediária $\Rightarrow$






$$e_j = (\sum e_n - w_{jn}) \cdot \frac{\delta F(\text{net})}{\delta \text{net}};$$

TREINAMENTO



FEEDFORWARD





FEEDBACKWARD



Fim do treinamento e o teste



Superfícies de erro




9. Proposta para o ETE



- Topologia Feedforward;
- Algoritmo Back-Propagation;
- Simulação da rede através de linguagem interpretada (Matlab);
- Posterior implementação da rede MLP (*Multi Layer Perceptron*) em hardware utilizando linguagem estruturada (C, C++, etc.);
- Base de dados para o treinamento e testes da rede obtidas com o programa de cálculo de equilíbrio de plasmas em tokamaks o TOPEOL.

10. Próxima Etapa

- Formar a base de treinamento e testes com o programa TOPEOL incluindo as bobinas de fluxo magnético;
- Simular a rede em Matlab;
- Listar opções de compra para o hardware neural;
- Especificar sistema de controle do campo magnético vertical (CCMV);
- Estudar possível implementação de rede neural artificial utilizando feedforward e back-propagation para uma modelagem mais simples como a de um sistema não-linear de levitação magnética.



Tokamak ETE em corte





TÍTULO

REDES NEURAIS NO MODELAMENTO E CONTROLE DE TOKAMAKS - APLICAÇÃO AO ETE (EXPERIMENTO TOKAMAK ESFÉRICO)

AUTOR

LUIS FILIPE DE F. P. W. BARBOSA

Gerson Otto Ludwig

TRADUTOR

EDITOR

ORIGEM

LAP

PROJETO

FUSÃO

SÉRIE

-

No. DE PÁGINAS

67

No. DE FOTOS

-

No. DE MAPAS

- 660

TIPO

☐ RPQ

☐ PRE

☐ NTC

☒ PRP

☐ MAN

☐ PUD

☐ TAE

☐

DIVULGAÇÃO

☒ EXTERNA

☐ INTERNA

☐ RESERVADA

☐ LISTA DE DISTRIBUIÇÃO ANEXA

PERIÓDICO / EVENTO

Primeiro Relatório: Doutorado - Área de Engenharia Nuclear/Fusão Controlada
Período de outubro/98 a setembro 99

CONVÊNIO

FAEPSP - Processo 98/06050-8

AUTORIZAÇÃO PRELIMINAR

04/12/99

DATA

Carimbo e Assinatura
Titular da Unidade

REVISÃO TÉCNICA

☐

SOLICITADA

☐

DISPENSADA

RECEBIDA ____/____/____ DEVOLVIDA ____/____/____

LABORATÓRIO ASSOCIADO DE FUSÃO

Carimbo e Assinatura
Titular de Nível "A"

Assinatura do Revisor

REVISÃO DE LINGUAGEM

☐

SOLICITADA

☐

DISPENSADA

RECEBIDA ____/____/____ DEVOLVIDA ____/____/____

Carimbo e Assinatura
Titular de Nível "A"

Assinatura do Revisor


AUTORIZAÇÃO FINAL

____/____/____
DATA

CARIMBO E ASSINATURA
TITULAR DE NÍVEL "A"
CENTRO DE TECNOLOGIAS ESPACIAIS

PALAVRAS-CHAVE

REDES NEURAIS ARTIFICIAIS / CONTROLE DA POSIÇÃO DO PLASMA EM TOKAMAKS / TOKAMAK / FUSÃO TERMONUCLEAR CONTROLADA / PLASMA



Folha 2/2

SECRETARIA	
____/____/____ DATA	RECEBIDA ____/____/____ DEVOLVIDA ____/____/____
_____ Encaminhado Por	_____ Devolvido Por

DATA <u>1/1</u>		RECEBIDO POR: <u>Yolanda</u>	DEVOLVIDO PARA: _____
PRONTO PARA PUBLICAÇÃO EM: <u>1/1</u>		<u>INPE-7252-PBF/220</u>	DATA <u>1/1</u>
No. _____	QUANT. _____	_____ Assinatura	

OBSERVATIONS