

TESE

1130

OLA FEDERAL DE ENGENHARIA DE ITAJUBÁ

***Um Modelo Neural Hierárquico para Previsão
de Cargas Elétricas em Sistemas de Potência***

CARLOS HENRIQUE LOUREIRO FEICHAS

ITAJUBA - M G

2001

EFEI – ESCOLA FEDERAL DE ENGENHARIA DE ITAJUBÁ

DISSERTAÇÃO DE MESTRADO



UM MODELO NEURAL HIERÁRQUICO PARA PREVISÃO
DE CARGAS ELÉTRICAS EM SISTEMAS DE POTÊNCIA

CARLOS HENRIQUE LOUREIRO FEICHAS

ORIENTADOR: PROF. Ph.D. OTÁVIO AUGUSTO SALGADO
CARPINTEIRO

CO-ORIENTADOR: PROF. Ph.D. ALEXANDRE P. ALVES DA
SILVA

ITAJUBÁ - MG

2001

CLASS. 621.316:004.032.26 (043-2)

CUT. F 297m

TOMBO. 1130



DISERTACION DE MESTRADO

EL MODELO NEURONAL PARA EL DISEÑO DE SISTEMAS DE CONTROL

DE CARGAS ELÉCTRICAS EN SISTEMAS DE POTENCIA

CARACTERÍSTICAS Y OBTENCIÓN DE

EL ESTADO DE EQUILIBRIO EN SISTEMAS DE POTENCIA

CARPINTERÍA

CO-ORDINADOR: PROF. DR. ALFONSO F. AGUIRRE

1977

ESTADO LIBRE SOBERANO DE YUCATAN

1977

A Deus, meus pais, irmãos, amigos e professores.

AGRADECIMENTOS

Agradeço em primeiro lugar a Deus, por me proporcionar esta oportunidade de estar concluindo este trabalho. Agradeço minha esposa Renata pelo apoio e compreensão pelas horas que estive ausente e ocupado, a meu irmão Marcus pelo auxílio e dedicação, a meus pais pela vida e pela grande contribuição em minha formação pessoal e cultural, aos professores Otávio Augusto S. Carpinteiro e Alexandre P. A. da Silva pela paciência e boa vontade em todos os momentos durante o desenvolvimento deste trabalho, e finalmente ao amigo Paulo Gomide Cohn pela força e incentivo.

RESUMO DA DISSERTAÇÃO

A previsão de carga a curto prazo tem um papel fundamental no planejamento de operações econômicas, confiáveis e seguras para o sistema elétrico. Em verdade, a precisão das previsões de cargas elétricas tem efeitos consideráveis na operação de sistemas elétricos de potência e nos custos de produção de energia. Assim, os operadores do sistema elétrico devem prever quais serão os padrões de carga no futuro próximo, de forma a prover o sistema com geração suficiente para atender a demanda.

Dada a complexidade e o custo envolvidos no problema, têm surgido diversos métodos para resolvê-lo de forma satisfatória. Estes métodos são geralmente separados em convencionais e não-convencionais. Este trabalho se baseia na utilização de um método não-convencional, redes neurais, que tem sido muito utilizado em previsões de cargas elétricas. A modelagem do problema de previsão de carga elétrica por Redes Neurais tem alcançado êxito, devido, sobretudo, ao seu inerente tratamento não linear das séries temporais de cargas elétricas e a sua robustez no tratamento das correlações existentes entre as variáveis envolvidas e a sua plasticidade.

O presente trabalho tem como objetivo o estudo da viabilidade de utilização de um modelo neural hierárquico, baseado no modelo de Kohonen, para previsão de cargas elétricas em Sistemas de Potência. O modelo possui um grande horizonte de tempo para eventos ocorridos no passado, capacitando-o, assim, a produzir previsões mais acuradas.

Dois experimentos com o modelo foram realizados e são apresentados, bem como seus resultados. Foi utilizada uma base de dados com valores de cargas elétricas reais de uma concessionária de energia elétrica brasileira.

ABSTRACT

Short-term load forecasting has a fundamental role in planning economical, safe and reliable operations for electric systems. Actually, the accuracy of electric load forecasting has considerable effects in the operation of electric power systems and in energy production costs. Therefore, the operators of the electric system should forecast which would be the load standards in the near future as to provide the system with sufficient generation to match the demand.

Due to the complexity and cost involved in the problem, many methods to satisfactorily solve it have been developed. These methods are generally divided into conventional and non-conventional. This work is based in the use of a non-conventional method, neural networks, which has been widely used in electric load forecasting. The modeling of the electric load forecasting problem through Neural Networks has achieved success, mainly due to its inherent non-linear treatment of the electric loads time series and its robustness in treating existing correlation between the involved variables and its plasticity.

The present work has the objective of studying the viability of the utilization of a hierarchical neural model, based on Kohonen's model, to forecast electric loads in Power Systems. The model has a great time horizon for events that took place in the past, thus capacitating it to produce more accurate forecasts.

Two experiments with the model were performed and are presented, as well as the results. A database was used with real electrical load values from a Brazilian electrical energy concessionary.

ÍNDICE

	Páginas
Agradecimentos	i
Resumo da dissertação	ii
Abstract	iii
Índice	iv
Índice de figuras	ix
Índice de tabelas	xii
Capítulo 1 – Introdução	1
Capítulo 2 – Redes Neurais Artificiais	
2.1 – Fundamentos de Redes Neurais	6
2.1.1 – Histórico de Redes Neurais	6
2.1.2 – O neurônio biológico	8
2.1.2.1 – Potencial de ação	13
2.1.3 – O neurônio artificial	14
2.1.3.1 - Neurônio booleano de McCulloch e Pitts	14
2.1.3.2 – Perceptrons	15

	V
2.1.4 – A Rede Neural Artificial	18
2.1.4.1 – Classificação das camadas de Redes Neurais	20
2.1.4.1.1 – Camada de entrada	20
2.1.4.1.2.- Camada intermediária	20
2.1.4.1.3 – Camada de saída	22
2.1.4.2 - Categorias das Redes Neurais (Topologia)	23
2.1.4.2.1 – Não recorrente	23
2.1.4.2.2 – Recorrente	24
2.1.4.3 – Aprendizado de uma Rede Neural	25
2.1.4.3.1 – Treinamento supervisionado	26
2.1.4.3.2 – Treinamento não supervisionado	27
2.1.4.4 - Desenvolvimento de aplicações utilizando Redes Neurais	27
2.1.4.4.1 – Levantamento de coleção de dados	28
2.1.4.4.2 – Separação dos dados	28
2.1.4.4.3 – Configuração da Rede	28
2.1.4.4.4 – Treinamento	29
2.1.4.4.5 – Teste	29
2.1.4.4.6 – Integração	29
2.2 – Rede Neural de Kohonen	30
2.2.1 – Um modelo auto organizável	30
2.2.2 – O mapa de Kohonen	31
2.2.3 – O algoritmo de Kohonen	32
2.2.4 – Vizinhança de neurônios	36

Capítulo 3 – Previsão de cargas em sistema de potência

3.1 – Introdução	38
3.2 – Objetivos da previsão de carga	39
3.3 – Importância da previsão de carga	40
3.4 – Aplicações da previsão de carga	41
3.4.1 – Sistemas puramente hidráulicos	41
3.4.2 – Sistemas puramente térmicos	42
3.4.3 – Sistemas mistos	42
3.5 – Técnicas de previsão de carga	42
3.5.1 – Curtíssimo Prazo	43
3.5.2 - Curto Prazo	43
3.5.3 - Médio Prazo	43
3.5.4 - Longo Prazo	44
3.6 – Fatores determinísticos na previsão de carga em sistemas de energia elétrica	44
3.6.1 – Fatores influenciados pelo tempo	45
3.6.2 – Fatores meteorológicos	46
3.6.3 – Fatores imprevisíveis	47
3.7 – Gerenciamento de Energia em Sistemas de Potência	48
3.8 – Métodos não convencionais de previsão de carga	49

Capítulo 4 – Um Modelo Neural Hierárquico para previsão de carga em sistemas elétricos de potência

4.1 – Introdução	50
4.2 – Representação dos dados	51
4.3 – O modelo neural hierárquico	53

Capítulo 5 – Testes e resultados obtidos utilizando o modelo neural hierárquico para previsão de carga em sistemas de potência

5.1 – Introdução	59
5.2 – Objetivos dos experimentos	60
5.2.1 – Realização dos estudos	60
5.2.2 – Experimento 1	63
5.2.2.1 – Estudo 1	64
5.2.2.2 – Estudo 2	65
5.2.2.3 – Estudo 3	66
5.2.2.4 – Estudo 4	67
5.2.2.5 – Estudo 5	68
5.2.2.6 – Estudo 6	69
5.2.2.7 – Estudo 7	70
5.2.2.8 – Tabela de erros	71
5.2.2.9 – Análise dos resultados dos estudos do experimento 1	72

	VIII
5.2.3 – Experimento 2	74
5.2.3.1 – Estudo 1	76
5.2.3.2 – Estudo 2	77
5.2.3.3 – Estudo 3	78
5.2.3.4 – Estudo 4	79
5.2.3.5 – Estudo 5	80
5.2.3.6 – Estudo 6	81
5.2.3.7 – Estudo 7	82
5.2.3.8 – Tabela de erros	83
5.2.3.9 – Análise dos resultados dos estudos do experimento 2	84
Capítulo 6 – Conclusão	
6.1 – Sumário	85
6.2 – Propostas para trabalhos futuros	88
Referências bibliográficas	90

Índice de Figuras

Figura 2.1 – Neurônio Biológico	10
Figura 2.2 – Conexões Sinápticas entre os neurônios	11
Figura 2.3 – O mecanismo da Sinapse	12
Figura 2.4 – Gráfico referente ao potencial de ação	13
Figura 2.5 – Unidade de McCulloch e Pitts	14
Figura 2.6 – Neurônio Artificial proposto por Rosenblatt	16
Figura 2.7 – Algumas funções de ativação	17
Figura 2.8 – Rede Neural em Camadas	19
Figura 2.9 - Um problema de classificação linearmente separável.	21
Figura 2.10 - Problema XOR, não linearmente separável.	22
Figura 2.11 - Rede Multilayer Perceptron	23
Figura 2.12 - Rede de Hopfield	25
Figura 2.13 – Mapa de Kohonen	32
Figura 2.14 – Treinamento da rede de Kohonen	36
Figura 4.1 - O modelo neural hierárquico	54
Figura 5.1 – Resultado da comparação entre a carga prevista e a carga real de uma sexta feira	64
Figura 5.2 – Resultado da comparação entre a carga prevista e a carga real de um sábado	65


Figura 5.3 – Resultado da comparação entre a carga prevista e a carga real de um domingo	
Figura 5.4 – Resultado da comparação entre a carga prevista e a carga real de uma segunda-feira	66
Figura 5.5 – Resultado da comparação entre a carga prevista e a carga real de uma terça-feira	67
Figura 5.6 – Resultado da comparação entre a carga prevista e a carga real de uma quarta-feira	68
Figura 5.7 – Resultado da comparação entre a carga prevista e a carga real de uma quinta-feira	69
Figura 5.8 - Resultado da comparação entre a carga prevista e a carga real de uma sexta-feira	70
Figura 5.9 - Resultado da comparação entre a carga prevista e a carga real de um sábado	76
Figura 5.10 - Resultado da comparação entre a carga prevista e a carga real de um domingo	77
Figura 5.11 - Resultado da comparação entre a carga prevista e a carga real de uma segunda-feira	78
Figura 5.12 - Resultado da comparação entre a carga prevista e a carga real de uma terça-feira	79
Figura 5.13 - Resultado da comparação entre a carga prevista e a carga real de uma quarta-feira	80
Figura 5.14 - Resultado da comparação entre a carga prevista e a carga real de uma quinta-feira	81

Figura 5.14 - Resultado da comparação entre a carga prevista e a carga real de uma quinta feira

Tabela 2.1 - Tabela XXXX

Tabela 2.2 - Tabela de comparação entre os resultados das análises

Tabela 2.3 - Tabela de comparação dos resultados das análises



Índice de Tabelas

Tabela 2.1 – Tabela XOR	21
Tabela 5.1 - Tabela de erros dos estudos do primeiro experimento	71
Tabela 5.2 – Tabela de erros dos estudos do segundo experimento	83

CAPÍTULO 1

Introdução

A previsão a curto prazo tem um papel fundamental no planejamento de operações econômicas, confiáveis e seguras para o sistema elétrico. São duas as principais áreas de aplicação de previsões a curto prazo.

A primeira área é a programação de geração de energia, visando o comissionamento mais econômico das fontes de geração, de forma consistente com os requisitos de confiabilidade, de restrições operacionais, e com as limitações físicas, ambientais e de equipamentos.

A segunda área encontra-se na segurança do sistema elétrico. A previsão de carga do sistema é requisito fundamental na detecção das condições futuras em que o sistema elétrico poderá estar vulnerável.

A precisão das previsões de cargas elétricas tem efeitos consideráveis na operação de sistemas elétricos de potência e nos custos de produção de energia. Os operadores do sistema elétrico devem se preocupar em prever quais serão os padrões de carga no futuro próximo, de forma a prover o sistema com geração suficiente para atender a demanda. Para tal, o operador deve manter no sistema níveis suficientes de reserva de energia, minimizando os impactos das incertezas contidas nas previsões. O custo operacional para manter tais níveis de reserva de energia é alto, posto que as unidades que compõem as reservas estão sub-utilizadas e usualmente operando bem abaixo de suas possibilidades. Desta forma, reduzindo-se a margem de erro das previsões, reduzem-se, outrossim, os níveis de reserva de energia e, por conseguinte, os custos operacionais, sem afetar, contudo a confiabilidade e a segurança do sistema [26,27].

Dada esta complexidade, e o custo envolvido no problema, têm surgido diversos métodos para resolvê-lo de forma satisfatória. Poder-se-iam classificá-los como métodos convencionais e não-convencionais.

Este trabalho se baseia na utilização de um método não convencional que tem se destacado, as *redes neurais*. A modelagem do problema de previsão de carga elétrica por redes neurais tem alcançado êxito, devido, sobretudo, ao seu eficaz tratamento não linear das séries temporais de demandas anteriores de cargas elétricas, a sua robustez no

tratamento das correlações existentes entre as variáveis envolvidas, e a sua plasticidade. Existem, no entanto, alguns problemas. Os resultados obtidos por intermédio de redes neurais são usualmente imprecisos sempre que haja variações sensíveis nos dados, como por exemplo, nas entradas de frentes climáticas quer sejam quentes ou frias, e, sobretudo, nas mudanças de estação anuais. Os resultados tendem igualmente a ser imprecisos devido à natureza não-estacionária da demanda da carga elétrica, que faz com que as cargas em um determinado dia e hora de um ano qualquer seja normalmente bem diferente da demanda deste mesmo dia e hora no ano seguinte.

O presente trabalho tem como objetivo o estudo da viabilidade da aplicação de um modelo neural hierárquico, no problema de previsão de cargas elétricas em sistemas de potência. O modelo, bem como a sua aplicação em sequências musicais são descritos na literatura [8-13].

O modelo neural hierárquico baseia-se em mapas auto-organizáveis de Kohonen (1972), e, dentre suas principais características, apresenta um grande horizonte de tempo para eventos ocorridos no passado. Tal horizonte de tempo ou memória para eventos passados pode ser aumentado ou reduzido de acordo com as necessidades da aplicação, através dos integradores de tempo [8-13]. A capacidade de memória para eventos passados concede ao modelo, igualmente, um amplo horizonte de tempo para previsões acuradas. Em suma, com uma melhor ‘lembrança’ do passado, o modelo pode ter um melhor ‘conhecimento’ do futuro.

Para o estudo de viabilidade da aplicação do modelo neural na previsão de cargas elétricas foram realizados estudos e experimentos sobre dados de carga reais cedidos por uma concessionária elétrica brasileira. Os resultados obtidos encorajam-nos a prosseguir os estudos sobre este modelo no futuro.

A dissertação está organizada em seis capítulos, sendo esta, *Introdução*, o primeiro deles.

O segundo capítulo, *Redes Neurais Artificiais*, apresenta uma breve revisão sobre os modelos clássicos de redes neurais, dando maior destaque ao modelo de Kohonen.

O terceiro capítulo, *Previsão de Cargas Elétricas em Sistemas Elétricos de Potência*, apresenta os conceitos e características gerais, referentes à previsão de cargas elétricas em sistemas de potência. Nele, são abordados fatores essenciais que afetam as cargas elétricas nos sistemas de gerenciamento de energia, e técnicas utilizadas no auxílio de suas operações, possibilitando um aumento da economia na geração, transmissão e, principalmente, segurança.

O quarto capítulo, *Um modelo Neural Hierárquico para previsão de carga em Sistemas Elétricos de Potência*, apresenta o modelo neural hierárquico utilizado na previsão de cargas elétricas. Este modelo é baseado no modelo auto-organizável de Kohonen, descrito no segundo capítulo.

O quinto capítulo, *Testes e resultados obtidos utilizando o modelo*, apresenta os resultados obtidos a partir de dois experimentos realizados com o modelo neural hierárquico. Os resultados são apresentados em tabelas e gráficos comparativos entre cargas elétricas reais e cargas elétricas previstas.

No sexto capítulo, *Conclusão*, apresentamos as conclusões obtidas a partir dos experimentos, sugestões para melhoria de desempenho e propostas para desenvolvimento de trabalhos futuros.

CAPÍTULO 2

Redes Neurais Artificiais

2.1 Fundamentos de Redes Neurais

2.1.1 - Histórico de Redes Neurais

A Neuro-Computação teve seu nascimento marcado por volta de 1943, pelos pesquisadores McCulloch e Pitts [1,22], com a publicação do artigo: “*A logical Calculus of the Ideas Immanent in Nervous Activity*”, que hoje é uma referência essencial para todas as teorias de redes neurais artificiais. Estes idealizadores sugeriram e obtiveram resultados na criação de uma máquina com neurônios artificiais inspirada no cérebro humano. A partir

desta data vários artigos e livros foram publicados e também outros nomes surgiram, como Hebb (1949), Ashby (1952), Rosenblatt (1958), Selfridge (1961), Block (1962), dentre outros.

Seguindo a história, por volta de 1970, pouco se falou e se publicou sobre o assunto, marcando uma fase de dormência nos estudos relacionados às Redes Neurais [22]. Isto aconteceu pela pequena credibilidade e pelo fraco potencial computacional que os modelos ofereciam.

Com o crescimento da computação digital, por volta de 1980, computadores mais velozes e poderosos foram surgindo, possibilitando a retomada de muitos trabalhos que estavam parados. Redes neurais maiores puderam ser desenvolvidas, com maior capacidade de processamento. Isso tudo gerou um maior desenvolvimento de soluções matemáticas e algoritmos de aprendizagem.

Seguindo esta retomada dos trabalhos, em 1983, Ira Skurnick do DARPA, fundou um grupo de pesquisas em Neuro-Computação cuja finalidade foi o desenvolvimento de projetos baseados nestes estudos.

Outro nome importante que surgiu em seguida foi o do físico John Hopfield. Ele se interessou pela área, fazendo estudos e publicando vários artigos, o que despertou o interesse de vários outros pesquisadores na época. Com este crescimento da comunidade científica, cada vez mais novos estudos surgiam, e mais artigos e livros eram publicados. A indústria eletrônica também crescia, máquinas mais poderosas eram produzidas,

aumentando cada vez mais a capacidade de desenvolvimento de algoritmos e modelos mais poderosos. Congressos também foram surgindo, possibilitando que pesquisadores apresentassem seus estudos e descobertas.

2.1.2 - O Neurônio Biológico

Antes de detalharmos qualquer tipo de modelo de rede neural, natural ou artificial, devemos destacar a grande influência das descobertas do passado nos estudos modernos, e também, conseqüentemente, toda a teoria atualmente conhecida. As aplicações produzidas nos dias de hoje, existem graças aos modelos matemáticos e de engenharia criados por vários pesquisadores e cientistas citados em 2.1.1.

Para entender o funcionamento de uma Rede Neural Artificial, é necessário conhecer primeiro o funcionamento de um neurônio natural (figura 2.1), bem como as redes neurais naturais (figura 2.2). Isto ocorre pelo fato da neuro-computação ser inspirada em nós, seres humanos, e no funcionamento dos organismos vivos.

Os organismos de vários seres vivos, assim como os dos seres humanos, reagem de acordo com estímulos internos e externos que lhes são proporcionados, sejam eles físicos ou químicos. Estes estímulos acionam células responsáveis pelo controle nervoso central, que nos possibilitam uma interação com o meio onde vivemos. Estas células são conhecidas como neurônios, e o conjunto delas e seus respectivos relacionamentos, rede neural natural[1,2,22].

Quando esta rede neural natural é ativada, nosso cérebro reage, respondendo conforme este estímulo. O que acontece pode ser descrito da seguinte maneira:

Ao serem acionados os sensores de nosso organismo, como a retina ocular, durante a visão, ou as papilas gustativas, quando saboreamos algum alimento, vários estímulos são gerados. Estes estímulos podem se propagar pelos axônios da célula nervosa se forem superiores a 50 mv, ou bloqueados, não prosseguindo em frente, no caso de serem inferiores a este valor [1].

Os estímulos na verdade são sinais elétricos que seguem pelos axônios, com a intenção de se transferir a outro neurônio. Estes sinais caminham pelo axônio, como uma corrente de íons positivos de sódio e potássio. Antes de o sinal elétrico entrar no próximo neurônio, deve passar por uma sinapse, que é o processo de ligação entre o axônio e o dendrito do outro neurônio. Se o sinal for superior a um certo limiar (threshold), vai em frente; caso contrário, é bloqueado e não segue.[1,2,19]

Na passagem por um neurônio, este sinal pode ser amplificado ou atenuado, dependendo do dendrito de origem, pois a cada condutor está associado um peso pelo qual o sinal é multiplicado. A memória na verdade, corresponde à modificação destes pesos.

Cada região do cérebro é especializada em uma dada função, como processamento de sinais auditivos, sonoros, elaboração de pensamentos, desejos etc. Esse processamento se dá através de redes particulares. Cada região do cérebro possui uma arquitetura de rede

diferente, onde varia o número de neurônios, de sinapses por neurônio, valor dos limiares, dos pesos, etc.

O valor dos pesos é estabelecido através de treinamentos recebidos pelo cérebro durante sua vida útil. Isto é conhecido como **memorização**.




Figura 2.1 - Neurônio biológico.

Conforme a figura 2.1, um neurônio é dividido em partes:

- **Corpo do neurônio:** É o processador da célula. Dele se projetam extensões filamentosas, os dendritos e os axônios.
- **Axônio:** É responsável pela condução do estímulo nervoso que é passado para o próximo neurônio.

- **Dendritos:** São ramificações que surgem no final do axônio. São responsáveis pela comunicação entre os neurônios através das sinapses.

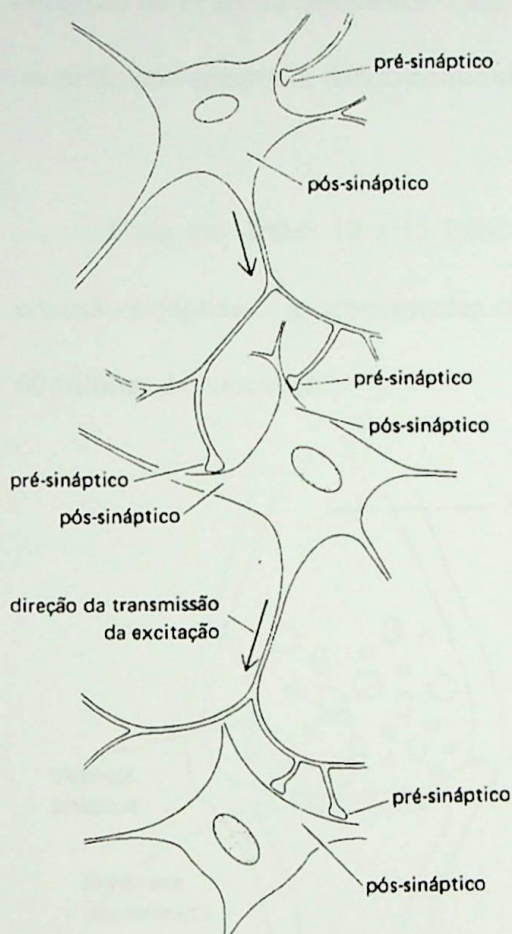


Figura 2.2 – Conexões Sinápticas entre os neurônios. Aqui podemos observar como os neurônios se comunicam uns com os outros, formando um emaranhado de conexões denominado Rede Neural Natural[19]

O termo rede neural é assim chamado, pois as células nervosas (neurônios) comunicam-se formando uma rede de neurônios (figura 2.2). Os processos de comunicação entre essas células acontecem através de ligações sinápticas, onde ocorre a passagem do sinal neural, através de processos eletroquímicos.

Entre um neurônio e outro existe uma pequena separação, chamado de fenda sináptica, onde um neurônio pré-sináptico liga-se a outro denominado neurônio pós-

sináptico (figuras 2.2 e 2.3). O impulso, também conhecido como sinal nervoso, que vêm através do axônio da célula pré-sináptica chega em sua extremidade e provoca na fenda a liberação de neurotransmissores. Este elemento químico se liga a receptores específicos no neurônio pós-sináptico, dando continuidade à propagação do sinal, ou não.

Cada um destes 10 a 15 bilhões de neurônios existentes no cérebro humano faz a conexão sináptica com aproximadamente 1000 a 10.000 outros neurônios, o que resulta em 60 trilhões de conexões.


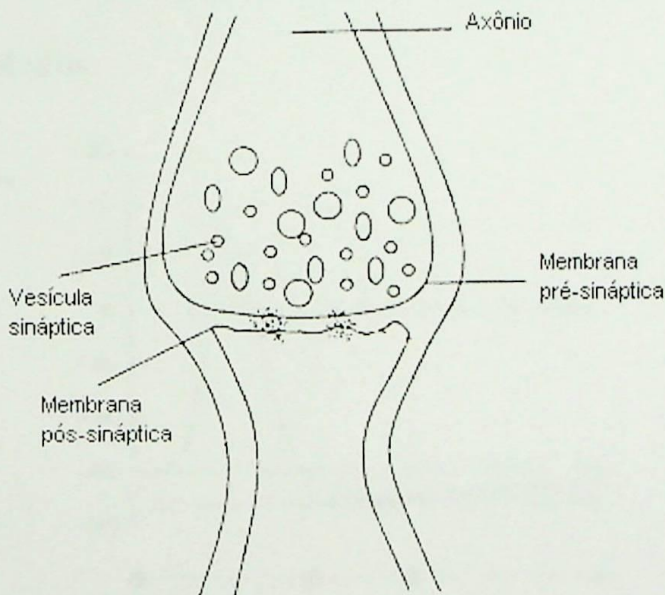


Figura 2.3 – O mecanismo da sinapse.

Pode-se dizer então, que o neurônio é uma célula com N entradas e uma única saída. As informações geradas na entrada acontecem através das conexões sinápticas, que conectam a árvore dendrítica aos axônios de outros neurônios. Um pulso elétrico que é transferido pelos axônios é na verdade a informação que a rede está processando.

2.1.2.1 – Potencial de Ação

Potenciais de ação são na verdade, os impulsos nervosos, ou seja, a informação sendo transferida entre os neurônios através de substâncias neurotransmissoras. O resultado dessa transferência é uma alteração do potencial elétrico da membrana pós sináptica, podendo durar até 1 ms (milissegundo). Durante este tempo a membrana varia de -70 para $+30$ mv retornando ao seu estado original, conforme figura 2.4 [1,2,19].

Dependendo do tipo de neurotransmissor, a conexão pode ser excitatória ou inibitória.




Figura 2.4 - Gráfico referente ao potencial de ação

T_n: Duração do impulso nervoso

T_a: Período de refração absoluta. Neste período a membrana é incapaz de produzir um outro potencial de ação

T_r: Período de refração relativa: Corresponde a elevação no limiar de disparo [1,2]

2.1.3 – O Neurônio Artificial

2.1.3.1 – Neurônio booleano de McCulloch e Pitts

Uma rede neural artificial é formada por uma infinidade de unidades de processamento. McCulloch e Pitts (1943) propuseram o primeiro modelo computacional, baseado em um neurônio biológico. Seu comportamento se baseia no fato que, em um determinado instante no tempo (t), o neurônio está ativo ou inativo, assumindo um valor 0 (zero) ou o valor 1 (um) [1,2,22,23].




Figura 2.5 – Unidade de McCulloch e Pitts

Os valores representados por X_1, X_2, \dots, X_p são os sinais de entrada que o neurônio recebe. Cada um destes sinais é multiplicado por um número, chamado de peso, que indica a sua influência na saída do resultado, de acordo com as entradas apresentadas ao neurônio. A influência do peso no resultado representa na verdade o tipo de conexão exercida naquele momento, excitatória ou inibitória, reforçando ou dificultando a propagação do impulso.

A produção do impulso gerado pelo neurônio produz uma saída igual a 1, se a soma das entradas for maior ou igual a um limite (limiar de disparo – Threshold).

2.1.3.2 – Perceptrons

Apesar de todos os estudos realizados, iniciando-se por volta de 1940, e prosseguindo-se até início da década de 50, marcados principalmente por McCulloch e Pitts, o primeiro modelo de rede neural implementado foi o “*perceptron*”, por Frank Rosenblatt (1959) [1].

Rosenblatt deu prosseguimento aos estudos de McCulloch e Pitts construindo esta rede, formada por vários neurônios que veio a ser denominado de *Rede de Perceptrons*.

O perceptron é uma rede neural simples, constituindo-se de uma camada de entrada e uma camada de saída. A cada elemento apresentado na entrada é atribuído um peso (W), no qual o valor de saída será a soma dos produtos de cada entrada pelo seu respectivo peso. Como definido por McCulloch e Pitts (1943), o neurônio possui um comportamento *tudo ou nada*, ou seja, **1** ou **0**. Entre o somatório dos produtos das entradas pelos seus respectivos pesos e a saída da rede, é necessário estabelecer uma função limiar que defina quando o neurônio estará ativo ou em repouso.

Em comparação ao modelo do neurônio natural (Figura 2.1), o neurônio artificial proposto por Rosenblatt (1959), é um modelo matemático, conforme figura 2.6.

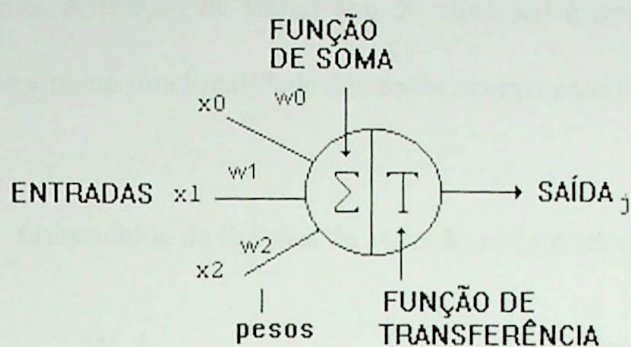


Figura 2.6 – Neurônio Artificial proposto por Rosenblatt.

As características do modelo de Rosenblatt são descritas da seguinte maneira:

- Um vetor com valores, aqui chamado de X , é utilizado como entrada de cada neurônio. Estas conexões possuem pesos associados, representando as variedades de estímulos que determinado neurônio apresenta em relação a outro.
- Os valores X_i são multiplicados pelos pesos W_i associados a cada entrada, e os resultados são aplicados a uma função de agregação, através da soma dos produtos entre X_i e W_i . O valor obtido é processado por uma função de ativação, que define o valor de saída do neurônio.
- A função de ativação pode induzir tanto uma saída binária, por exemplo, $y=\{0,1\}$, quanto valores contínuos, em um intervalo, por exemplo, $y=[0,1]$. O valor de ativação do neurônio é calculado a partir da aplicação da função de limiar ao valor de entrada fornecido ao

neurônio. A função de limiar (ou de ativação) é um tipo de função não linear, no qual garante a plena funcionalidade das redes neurais com várias camadas.

Os modelos de funções de ativação podem ser observados nesta figura.

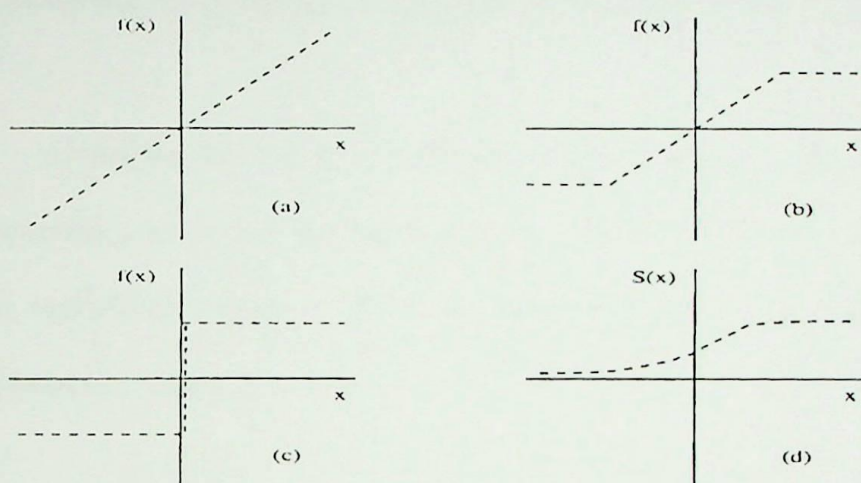


Figura 2.7 – Algumas funções de ativação. A escolha destas funções depende da aplicação a ser desenvolvida

Apesar do impacto revolucionário causado pela criação do perceptron naquela época, este modelo foi muito criticado por Minsky e Papert (1969), proporcionando até a publicação de um livro que eles intitularam *Perceptrons*. Nesta obra eles citam um problema, no qual, o Perceptron com uma simples camada não poderia simular, o comportamento de uma simples função XOR (ou-exclusivo). Após esta publicação, iniciou-se um período de dormência dos estudos relacionados a redes neurais, pois esta revelação desencorajou novas pesquisas, e pelo fraco potencial que os modelos apresentavam.

Este problema descrito por Minsky e Papert (1969), é apresentado em 2.1.4, e pode ser melhor observado em [1,22].

2.1.4 – A Rede Neural Artificial

O modelo de rede neural artificial tem características que simulam o funcionamento de uma rede neural natural, ou seja, são neurônios ligados por conexões sinápticas formando uma teia de conexões, fazendo jus a esta denominação.

O modelo proposto por Rosenblatt (1959), foi verificado que por si só não era capaz de aprender e resolver problemas complexos. Para solucionar este problema era necessário mais conexões com outros neurônios, os quais só era possível em uma rede de perceptrons dispostos em várias camadas.

Foi criado, então, o modelo *Multilayer Perceptron*, onde os neurônios da rede são arrançados, de maneira que um conjunto deles é utilizado como camada de entrada, que será responsável pela entrada de dados da rede. Um outro conjunto de neurônios é disposto em uma outra camada, chamada de camada oculta, onde acontece a maior parte do processamento, e um outro conjunto utilizado como terceira camada, que será responsável pela saída de dados da rede (Figura 2.8).

A camada de neurônios intermediária, conhecida como oculta, é de grande importância, pois se provou que sem ela, se torna impossível a resolução de problemas linearmente não separáveis.

A cada conexão dos neurônios é associado um peso, indicando a importância desta conexão em relação à saída do resultado. As unidades fazem operações sobre seus dados

locais, que são entradas recebidas pelas suas conexões. O comportamento inteligente de uma Rede Neural Artificial vem das iterações entre as unidades de processamento da rede.

Para que a rede neural solucione problemas corretamente, é necessário que a ela sejam aplicados um conjunto de procedimentos. Estes procedimentos são conhecidos como treinamento de Redes Neurais. A finalidade destes treinamentos é o ajustamento dos pesos de acordo com o modelo, aprendendo através de exemplos.

O processo de treinamento é realizado a partir de casos reais conhecidos, adquirindo, a partir daí, a capacidade para a resolução do problema ou problemas para a qual foi treinada. Sendo assim, a Rede Neural é capaz de codificar regras básicas nos seus pesos, diferindo da computação programada convencional, onde é necessário um conjunto de regras rígidas pré-fixadas e algoritmos.

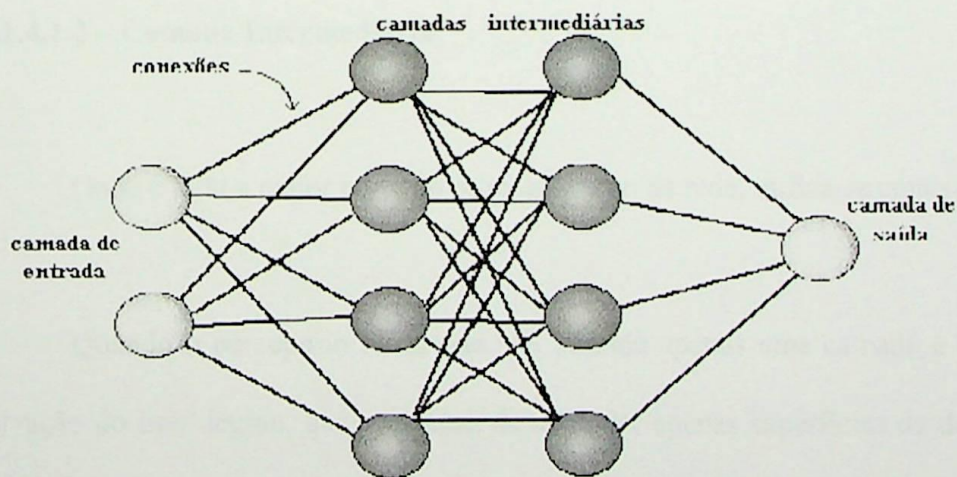


Figura 2.8 – Rede Neural em Camadas: Uma de entrada, duas ocultas e uma de saída.

2.1.4.1 – Classificação das Camadas de Redes Neurais

Cada camada de uma Rede Neural tem uma atividade específica. Elas são definidas como:

- Camada de entrada
- Camada intermediária
- Camada de saída

2.1.4.1.1 – Camada de Entrada

Os padrões são apresentados à rede como entrada de dados. Um conjunto de dados é escolhido e inserido na Rede, como dados que serão processados.

2.1.4.1.2 – Camada Intermediária

Onde é feita a maior parte do processamento da rede, utiliza-se conexão ponderada.

Quando o perceptron foi criado, ele possuía apenas uma camada e uma função de ativação do tipo degrau, que era capaz de aprender apenas superfícies de decisão lineares. Isto significa que deveria haver uma separação linear nítida entre os resultados esperados para que o perceptron fosse capaz de aprender.




Figura 2.9 - Um problema de classificação linearmente separável.

Minsky e Papert (1969), descreveram este problema, e criaram alguns exemplos para demonstrá-lo.

XOR é um exemplo que eles utilizaram.

Ele consiste:

- Duas entradas binárias são processadas e produzem saída 1, somente se, apenas uma das entradas for 1. Caso as entradas sejam dois valores 0 (zero), ou dois valores 1 (um), a saída será igual a 0 (zero), conforme tabela 2.1.

X1	X2	X1 XOR X2
0	0	0
0	1	1
1	0	1
1	1	0

Tabela 2.1 – Tabela XOR

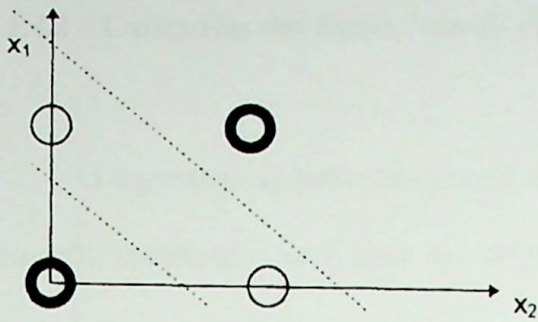


Figura 2.10 - Problema XOR, não linearmente separável.

Neste caso, são quatro padrões e dois resultados possíveis. O perceptron não consegue aprender, porque não há superfície de decisão elíptica.

Para resolver problemas como este, foi apresentada a idéia da utilização de mais de uma camada de neurônios, onde encontramos, no mínimo, uma camada de entrada, uma camada de saída e uma camada intermediária, chamada de oculta (Figura 2.10). Um maior detalhamento do exemplo XOR e a solução encontrada, pode ser observado em [1].

2.1.4.1.3 – Camada de Saída


Saída do resultado processado pela Rede Neural.

2.1.4.2 – Categorias das Redes Neurais (Topologia)

O algoritmo de aprendizagem de uma rede neural está relacionado com o tipo de formação estrutural e topológica dos neurônios. Vários tipos de modelos de Redes foram surgindo com o intuito de tentar melhorar o desempenho nas atividades nas quais elas eram submetidas.

Dentre eles podemos citar dois:

- Não recorrente
- Recorrente



2.1.4.2.1 – Não Recorrente

Esta topologia de rede apresenta uma ou mais camadas ocultas [22].




Figura 2.11 - Rede Multilayer Perceptron [22].

Os dados de entrada da rede são fornecidos em forma de um vetor, que representam os sinais de entrada aplicados aos neurônios da próxima camada, e assim sucessivamente até a saída do resultado. Neste tipo de topologia, é necessário o mínimo de duas camadas, a de entrada de dados e a de saída de dados. A ausência de camadas ocultas não é considerada uma técnica muito eficiente, não apresentando desempenho muito bom, conforme visto em 2.1.4.1.2.

Cada neurônio da Rede está ligado com todos os outros neurônios da camada vizinha. Neurônios da mesma camada não se comunicam.

Observe então, que o fluxo da informação (dados) se propagam em apenas um único sentido. Portanto, este tipo de topologia é conhecido também como Rede de Propagação Unidirecional.

2.1.4.2.2 – Recorrente

Neste tipo de arquitetura, cada neurônio da rede apresenta um processo de realimentação, ou seja, os sinais de saída dos neurônios são retornados para alguns ou para todos os neurônios das camadas anteriores [22].

Observe estas características na figura 2.12.




Figura 2.12 - Rede de Hopfield [22].

É possível que a rede tenha apenas uma única camada. A informação se transmite em todas as direções, onde todos os neurônios se comunicam. O comportamento deste tipo de rede é dinâmico e geralmente não existe camada intermediária.

Esta arquitetura é muito utilizada para reconhecimento de padrões.

2.1.4.3 – Aprendizado de uma Rede Neural

A principal característica de uma rede neural é a capacidade de melhorar seu desempenho, a partir de alterações ocorridas em seus dados, gerando conseqüentemente um melhor resultado para um problema onde ela se aplica. Esta melhoria de desempenho ocorre com o tempo, durante seu treinamento.

Podemos dizer que uma rede neural artificial “aprende” quando ela é capaz de ajustar os pesos das conexões entre seus neurônios (sinapses), de acordo com os estímulos provenientes do ambiente no qual ela está inserida [22].

A melhoria dos pesos entre as conexões sinápticas acontece através de um processo iterativo de ajustes, chamado de treinamento.

Existem dois tipos de treinamentos aplicados em Redes Neurais:

- Treinamento supervisionado
- Treinamento não supervisionado

2.1.4.3.1 – Treinamento Supervisionado

Neste tipo de treinamento se conhece o resultado que deve ser gerado. Se a saída da rede não for o correto (esperado), em comparação com os resultados reais, os pesos das sinapses serão reajustados de forma a aumentar a precisão da resposta da rede. Uma saída incorreta é conhecida como erro. O erro é definido como a diferença entre a resposta desejada e a resposta real da rede.

2.1.4.3.2 – Treinamento Não Supervisionado

Neste tipo de treinamento, a rede deve ser capaz de se auto-organizar, reajustando seus pesos, sem a interferência de agente externo na verificação do resultado obtido. Os ajustes dos pesos são realizados internamente.

2.1.4.4 – Desenvolvimento de aplicações utilizando Redes Neurais

Para o desenvolvimento de aplicações, utilizando Redes Neurais Artificiais, é necessário seguir uma seqüência de passos, tais como:

- Levantamento e coleção de dados
- Separação dos dados
- Configuração da Rede
- Treinamento
- Teste
- Integração

Após o treinamento e avaliação da Rede, ela pode ser integrada no ambiente para o qual fora desenvolvido.

2.1.4.4.1 - Levantamento e coleção de dados

Deve-se primeiramente conhecer bem o problema no qual se deseja aplicar redes neurais. Os dados levantados devem refletir com veracidade o domínio do problema, cobrindo não só operações normais ou rotineiras, como também as exceções e as condições nos limites deste domínio em questão.

2.1.4.4.2 - Separação dos dados

Os dados abstraídos do problema devem ser divididos em dois conjuntos:

- Treinamento
- Testes

Um conjunto dos dados é separado e utilizado para treinamento da rede. Geralmente este conjunto varia de 50 a 90% do total de elementos, e são coletados aleatoriamente.

2.1.4.4.3 - Configuração da Rede

Este passo é reservado à escolha da topologia da rede, função de ativação, etc.

2.1.4.4.4 – Treinamento

Escolha do algoritmo de treinamento. Modo como a rede será inicializada e o tempo necessário para o treinamento.

2.1.4.4.5 - Teste

O conjunto de teste é utilizado para verificar a performance da Rede

2.1.4.4.6 - Integração

Após o treinamento e avaliação da Rede, ela pode ser integrada no ambiente para o qual fora desenvolvido.

2.2 - Rede Neural de Kohonen

Assim como Minsky, Papert, Rosenblatt, dentre muitos, outro pesquisador, chamado Teuvo Kohonen, propôs um modelo para a formação e funcionalidade de mapas topográficos, baseados nas atividades do cérebro [22-25]. Seu modelo apresenta características particulares bem diferentes do que se tinha conhecimento na época, como mapa auto-organizável, com treinamento não-supervisionado.

2.2.1 – Um modelo auto-organizável

Ao contrário do perceptron de McCulloch e Pitts (1943), o modelo introduzido por Kohonen não se limita apenas a valores binários, ou seja, os dados de entrada, os pesos e as saídas podem ser valores contínuos. Ele estabeleceu que um grande número de neurônios, vizinhos a um neurônio chamado de *vencedor*, pode representar o padrão de entrada. O modelo realiza um mapeamento, que localiza o melhor conjunto de neurônios com maior probabilidade de solucionar o problema.

Vários estudos demonstram que o cérebro é dividido em partes, cada uma delas com a finalidade de controlar certas atividades do organismo, como a visão o sistema de movimentos, raciocínio, desejos, etc [2]. Baseado nestes estudos, Kohonen projetou um modelo neural artificial que simula os mapas topográficos do cérebro, de forma que um conjunto de neurônios seja localizado, sempre que determinadas atividades sejam exercidas nas entradas da rede [24,25].

Tal modelo caracteriza-se por trabalhar com treinamento não-supervisionado e principalmente, ser auto-organizável, onde os neurônios são inibidos por outros neurônios, fazendo com que a competição entre eles leve à apenas um acabar mais excitado, isto é, um único neurônio vencedor. O ajuste dos pesos ocorre então não somente com os pesos deste neurônio vencedor, mas também com os pesos de neurônios próximos a ele.

2.2.2 - O Mapa de Kohonen

No modelo de Kohonen, os neurônios da camada de saída disputam a representação da informação apresentada aos neurônios na camada de entrada da rede. Apenas um único neurônio será considerado o vencedor, porém, este neurônio, diferentemente dos outros modelos de rede neural, não será o responsável pela representação da informação. Ele servirá como parâmetro para que um conjunto de neurônios vizinhos a ele sejam também os responsáveis pela representação.

O modelo que Kohonen propõem, é baseado nas atividades cerebrais dos organismos vivos, onde as células são organizadas anatomicamente, de acordo com os estímulos recebidos.

Na figura 2.13, é mostrada uma rede neural de Kohonen, os neurônios não são arranjados em camadas como no modelo Multilayer Perceptron (camadas de entrada, oculta e saída), mas sim dispostas em um mapa (ou grid). Todas as entradas conectam com todos as unidades de saída, que por sua vez e conectam com seus vizinhos adjacentes.[22]

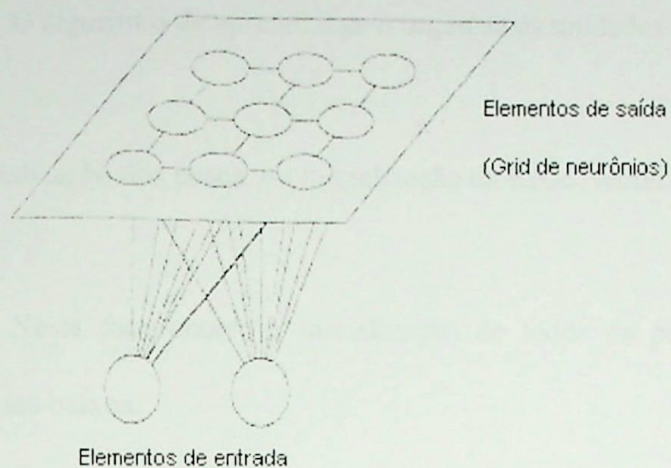


Figura 2.13 – Mapa de Kohonen. Neurônios de saída são utilizados de forma bidimensional. Todas as entradas estão conectadas com todas as saídas.

2.2.3 O Algoritmo de Kohonen

O algoritmo de aprendizagem criado por Kohonen, organiza as unidades no mapa em vizinhanças, que agem como classificadores de características nos dados de entrada. A topografia do mapa é organizada de forma autônoma, por um processo cíclico de comparação de padrões de entrada com vetores de pesos de cada unidade no mapa.

O algoritmo de aprendizagem organiza as unidades no mapa, da seguinte maneira:

1. Inicialização dos pesos, ou inicialização da Rede Neural.

Nesta fase ocorre a inicialização de todos os pesos das sinapses, com valores aleatórios baixos.

Defina $w_{ij}(t)$, para ser o peso da unidade de entrada i para a unidade de saída j (no mapa), no tempo t .

2. Apresentar os dados de entrada à rede neural.

Apresente à rede o padrão de entrada $X_0(t), X_1(t), X_2(t), \dots, X_{n-1}(t)$

onde:

$X_i(t) \rightarrow$ É o padrão para a unidade de entrada i no tempo t

3. Calcular as distâncias d_j entre o padrão de entrada i e cada unidade j no mapa.

Para cada unidade no mapa, calcular a distância euclidiana d_j entre a unidade j e o padrão de entrada i , dado por :

$$d_j(t) = \sqrt{\sum_{i=0}^{N-1} (x_i(t) - w_{ij}(t))^2}$$

onde:

$x_i(t)$ = Valor do neurônio de entrada no tempo t

$w_{ij}(t)$ = Peso sináptico entre o neurônio de entrada i e o neurônio de saída j no tempo t .

Neste momento acontece a seleção do neurônio vencedor, ou seja, aquele que apresentar a menor distância.

O neurônio que apresentar o menor $d_{ij}(t)$ é o vencedor da competição

4. Atualização de pesos da vizinhança do neurônio vencedor.

A atualização de pesos é realizada no próprio neurônio vencedor, bem como numa área que abrange $NE(t)$ neurônios à sua volta, e essa atualização obedece ao seguinte cálculo:

$$w_{ij}(t+1) = w_{ij}(t) + n(t) \cdot (x_i(t) - w_{ij}(t))$$

onde:

$n(t)$ = taxa de aprendizagem que deve ser diminuída no decorrer do treinamento.

$NE(t)$ = número de neurônios vizinhos afetados pela atualização de pesos.

5. Voltar ao passo 2, até que não sejam observadas modificações significativas no mapa.

O ciclo de treinamento é dividido em duas etapas:

1ª Etapa: **Coarse Mapping** (Mapeamento grosseiro)

Pretende-se que durante esta fase, a rede ‘defina’ quantas classes de padrões o mapa deve identificar, e onde elas devem estar em relação a cada outra no mapa. Normalmente o tamanho das vizinhanças deve ser grande, permitindo grandes modificações nos pesos, esperando povoar o mapa o mais rápido possível.

2ª Etapa: **Fine Tuning** (Refinamento)

Uma vez que a representação das classes de padrões é definida, o aprendizado das unidades no mapa que representam estas classes deve ser refinado com relação aos padrões de entrada.

Durante esta fase, tanto a taxa de aprendizagem quanto o tamanho das vizinhanças são reduzidos. Geralmente, a fase de refinamento leva de 100 a 1000 vezes mais passos que a fase de mapeamento grosseiro.

2.2.4 - Vizinhança de neurônios

Durante o processo de aprendizagem, o conjunto de neurônios que responde a um padrão qualquer vai se tornando cada vez menor e especializado. Segundo Kohonen (1987, 1989), a melhor auto-organização da Rede acontece quando o conjunto de vizinhos começa com um grande número de neurônios, diminuindo durante o treinamento [22,24,25].

Na figura abaixo podemos observar como a vizinhança que responde a um determinado padrão é reduzida durante o treinamento.

Observe:




Figura 2.14 – Treinamento na rede de Kohonen

No diagrama A da figura 2.14, a rede é mostrada em seu estado inicial. O vetor de pesos de cada unidade no mapa possui valores aleatórios, estando dispostos de forma desordenada e com o tamanho da vizinhança bem grande. Para cada padrão de entrada, durante o treinamento, um neurônio vencedor é encontrado tendo a partir deste momento seu peso atualizado, bem como todos os neurônios em uma determinada vizinhança ao seu redor.

No diagrama B, podemos observar que o tamanho da vizinhança é reduzido e os neurônios dentro desta vizinhança vão se ajustando para responder melhor a um determinado padrão de entrada.

No diagrama C, podemos observar o treinamento completo da rede. O tamanho da vizinhança foi bastante reduzido e os neurônios dentro desta vizinhança estão bem ajustados, respondendo melhor ainda ao padrão de entrada.

A redução do tamanho da vizinhança durante o treinamento é importante para a formação do mapa. Segundo Kohonen (1989), não apenas o neurônio vencedor, mas todo o conjunto de neurônios vizinhos a ele representa a informação dada por um padrão de entrada qualquer [25].

CAPÍTULO 3

Previsão de Carga em Sistemas de Potência

3.1 – Introdução

A previsão de carga em sistemas de potência se relaciona muito com o planejamento e operação de um sistema de energia elétrica. Quando um sistema de previsão é estabelecido adequadamente, podem ocorrer reduções de custos operacionais e aumento da segurança de um sistema elétrico.

Existem hoje muitos estudos e pesquisas voltados à solução de problemas, desenvolvimento de novas tecnologias, aplicação de métodos preventivos e de tomada de decisão, facilitando o dia-a-dia das grandes concessionárias de energia elétrica.

O planejamento da operação de um sistema elétrico de potência necessita das cargas elétricas em três situações de tempo [27,28]:

- Horárias
- Diárias
- Semanais

3.2 – Objetivos da previsão de carga

Todo sistema, seja ele qual for, deve atender a certas especificações e padrões para que o usuário final possa se sentir confortável e seguro com o serviço a ele prestado. Em sistemas elétricos, essa definição não é diferente; o objetivo principal é atender as cargas elétricas necessárias com máximo de economia e qualidade, respeitando as restrições elétricas, econômicas e ambientais. É necessário então, no planejamento de um sistema elétrico, a previsão das alterações na carga, de forma que a geração e transmissão sempre aconteçam de forma confiável, evitando sobrecarga ou falta de energia em determinados horários e dias da semana.

Esta harmonia entre a geração de energia e o consumo, propicia um equilíbrio do sistema, evitando problemas de elevação e queda de tensão, auxiliando a operação do sistema.

3.3 – Importância da previsão de carga



A previsão a curto prazo tem um papel fundamental no planejamento de operações econômicas, confiáveis e seguras para o sistema elétrico. A precisão das previsões de cargas elétricas tem efeitos consideráveis na operação de sistemas elétricos de potência e nos custos de produção de energia. Portanto, os operadores do sistema elétrico devem prever quais serão os padrões de carga no futuro próximo, de forma a prover o sistema com geração suficiente para atender a demanda.

Assim sendo, só é possível fazer previsão quando se mantém um histórico de cargas passadas ocorridas em diferentes momentos. A antecipação de valores de cargas tem a importância de indicar quais os procedimentos que podem ser tomados para um comissionamento mais econômico das fontes de geração, de forma consistente com os requisitos de confiabilidade, restrições operacionais, limitações físicas, ambientais e de equipamentos.

A previsão de carga do sistema pode também fornecer dados importantes, onde através deles é possível se detectar as condições futuras, sob as quais o sistema de potência pode estar vulnerável. Estas informações permitem aos operadores tomarem decisões corretivas necessárias, com o objetivo de operar o sistema de forma mais segura.

3.4 – Aplicações da previsão de carga

A previsão de carga, como já mencionado, é de vital importância para um planejamento das estratégias de operação de um sistema de energia elétrica. Com uma boa estratégia de operação definida e implantada vários fatores benéficos podem ser apresentados.

A previsão de cargas elétricas pode ser aplicadas em três tipos de sistemas:

- Sistemas puramente hidráulicos
- Sistemas puramente térmicos
- Sistemas mistos

3.4.1 – Sistemas puramente hidráulicos

Neste tipo de sistema, o volume de água utilizado na geração é de fundamental importância. A previsão se aplica na programação mais econômica das unidades de geração, onde o volume de água vertido pelos reservatórios e os níveis de geração nas usinas devem ser observados.

3.4.2 – Sistemas puramente térmicos

A programação das unidades geradoras também é um aspecto importante neste tipo de sistema, cuja finalidade é determinar o custo mínimo dos acionamentos e paradas das unidades utilizadas na geração de energia.

3.4.3 – Sistemas mistos

Nos sistemas mistos, ou seja, hidráulicos e térmicos, a principal vantagem de se utilizar a previsão de carga diz respeito à função de coordenação hidrotérmica, na programação da operação horária das várias unidades geradoras com o intuito de minimizar os custos relativos à produção.

3.5 – Técnicas de previsão de carga

Toda carga gerada deve ser aplicada e sempre monitorada para que a necessidade de consumo seja atendida em todo momento. Isso acontece através de várias atividades de controle, e técnicas desenvolvidas de acordo com estudos realizados.

As técnicas de previsão podem ser classificadas em:

- Curtíssimo Prazo
- Curto Prazo
- Médio Prazo
- Longo Prazo

3.5.1 – Curtíssimo Prazo

A previsão se baseia em dados relativos há poucos minutos, até uma hora à frente. Geralmente, dados que precisam ser manipulados tão rapidamente, a um espaço de tempo tão pequeno, atendem a sistemas de operação on-line.

Em computação, dados manipulados instantaneamente se referem a operações onde o tempo de requisição de dados e as respostas são cruciais para a funcionalidade perfeita do processo automatizado.

3.5.2 - Curto Prazo

Técnica utilizada para operação horária, diária, podendo chegar até períodos de uma semana à frente. O sistema tende a atender o mais rápido possível, sem alterações na curva de nível de carga, evitando alterações de tensão. A programação das unidades geradoras, bem como controle das reservas operativas, e programação de intercâmbios com outras áreas do sistema podem ser realizados utilizando esta técnica.

3.5.3 - Médio Prazo

O planejamento de operação elétrica, programação energética e da manutenção de equipamentos, vai de uma semana a um ano. Neste caso, pode-se verificar oscilações de cargas um pouco maiores envolvendo a entrada e saída de unidades geradoras e o intercâmbio de potência com sistemas vizinhos.

3.5.4 - Longo Prazo

O planejamento de expansão do sistema é superior a um ano, podendo chegar até 10 anos. As oscilações das cargas aumentam mais ainda, com relação as anteriores, funções ligadas à programação energética e manutenção de equipamentos são executadas. Técnica muito utilizada também em situações de planejamento e dimensionamento de novos equipamentos e unidades de geradoras.

3.6 – Fatores determinísticos na previsão de carga em sistemas de energia elétrica

As cargas em um sistema elétrico de potência são obtidas através da soma de toda requisição individual efetuada pelos consumidores, sejam eles considerados de pequeno, médio ou de grande porte. Todos os equipamentos que estes clientes utilizam, e que consomem energia, causam grandes dificuldades de se prever a demanda de carga elétrica necessária. É praticamente impossível ter-se conhecimento individual de cada um destes consumidores, senão poderíamos determinar um modelo de carga do sistema.

As demandas individuais são caracterizadas pela utilização de [27]:

- Equipamentos de Iluminação
- Aparelhos de ar condicionado
- Motores elétricos
- Fornos elétricos
- Etc.

Existem métodos estatísticos que podem auxiliar na previsão da carga, se toda a demanda de carga for levada em consideração como um conjunto de cargas, e também certas tendências de consumo.

Dentre todos os fatores que influenciam a carga, podemos classificá-los em três grupos [29]:

3.6.1 – Fatores influenciados pelo tempo

Certas épocas do ano há uma variação de consumo, reflexo das condições temporais e meteorológicas. Podemos destacar:

- Finais de semana
- Feriados prolongados
- Férias escolares
- Queda de temperatura
- Aumento da temperatura

A previsão de carga deve se preocupar muito com estes fatores, pois nestes períodos do ano há uma grande variação do consumo de energia, principalmente nas residências. O aumento ou diminuição do tempo de permanência da luz solar, de acordo com a mudança da estação, pode também influenciar na variação de consumo de energia.

3.6.2 – Fatores meteorológicos

A queda de temperatura, talvez seja um dos fatores mais significativos no aumento de consumo de energia elétrica. Devido a isto, são tomadas algumas medidas de economia, como: mudanças no horário adotado pelo governo federal, dentre outras.

Geralmente no inverno certos equipamentos são utilizados com mais frequência, tais como:

- Aquecedores de Ambiente
- Torneiras Elétricas com aquecimento de água
- Chuveiros utilizados em temperaturas mais elevadas

Todos estes equipamentos utilizados por várias pessoas ao mesmo tempo, em horários onde a queda de temperatura é mais elevada, influenciam muito na carga.

O aumento da temperatura também tem sua influência na carga, devido a alguns fatores:

- Maior utilização de equipamentos para ventilação de ambientes, como ventiladores e Aparelhos de condicionamento de ar.
- Maior utilização de Refrigeradores
- Etc.

3.6.3 – Fatores imprevisíveis (aleatórios)

Acontecem sem dia nem horário marcado. A previsão, nestes tipos de acontecimentos é incerta; não se sabe a carga exata exigida.

Destacam-se:

- Utilização de equipamentos de sonorização e iluminação para aglomerado de pessoas, como shows, comícios políticos, greves de movimentação em massa, transmissão de programas de televisão de interesse geral, dentre outros.
- Períodos de copa do mundo, novelas, futebol em decisões de campeonatos, onde os consumidores utilizam seus televisores e outros equipamentos no mesmo horário.

Com tudo isso, pode-se notar como a previsão de carga é complicada, certos acontecimentos são praticamente imprevisíveis, dificultando a implantação de medidas de controle preventivo, de maneira que a geração seja sempre a necessária no atendimento das necessidades dos consumidores.

3.7 – Gerenciamento de Energia em Sistemas de Potência

A geração de energia deve ser suficiente para satisfazer a demanda; isso quer dizer que uma antecipação de padrões de cargas, integridade das informações e precisão dos dados, são muito importantes para o sistema. Manter reservas auxiliares para aliviar os impactos das incertezas contidas nas previsões pode se tornar muito caro, por isso, quanto menor o erro da previsão, os níveis de reserva podem ser reduzidos sem afetar a confiabilidade e a segurança do sistema.

A informática tem um papel muito importante nos sistemas de previsão de carga. Grande parte da operação é realizada utilizando-se softwares de gerência e de tomada de decisão, aumentando a confiabilidade e a sensibilidade nas atividades relacionadas à carga. Grandes bases de dados com históricos de cargas, informações meteorológicas, dentre outras, são utilizadas, sendo de vital importância para a operação do sistema.

3.8 – Métodos Não Convencionais de previsão de carga (qualitativos – baseados em conhecimento)

O crescimento dos setores de energia elétrica aumentou também sua complexidade, exigindo que vários métodos fossem surgindo. As novas técnicas desenvolvidas não foram somente baseadas em análises matemáticas complexas, mas sim, técnicas que possuem a capacidade de adaptação de acordo com as alterações do ambiente onde elas se propõem a atender às soluções dos problemas.

Redes Neurais Artificiais é a que mais se destaca na solução dos problemas em sistemas elétricos de potência e a técnica que utilizo neste trabalho. Ela tem sucesso na modelagem de séries temporais e possui a capacidade de adaptação a conjunto de dados, com diferentes características. Esta adaptação deve acontecer devido a variações dos dados, de acordo com os fatores destacados anteriormente.

Outra característica das redes neurais artificiais é a mudança de comportamento devido ao aprendizado que são capazes de apresentar, diante tais mudanças do sistema. Isto torna este método em uma das melhores soluções utilizadas em sistemas de previsão.

CAPÍTULO 4

Um modelo Neural Hierárquico para previsão de carga em Sistemas Elétricos de Potência

4.1 – Introdução

O modelo neural hierárquico para previsão de carga em sistemas de potência apresentado neste capítulo foi empregado nos experimentos do capítulo seguinte. Neste quarto capítulo, descreveremos não só o modelo, como também a representação dos dados utilizada.

4.2 – Representação dos dados

Os dados de entrada consistem em cargas elétricas reais extraídas de uma concessionária brasileira de energia. Estes dados constituem-se em uma seqüência de valores de cargas, de hora em hora, por um período de 90 dias. Os dados de carga são normalizados, variando no intervalo [0,1].

Sete unidades neurais são usadas nesta representação, da seguinte maneira :

$$C(k) \ C(k-1) \ C(k-23) \ C(k-167) \ C(k-191) \ HS(k+1) \ HC(k+1) \quad (1)$$

onde:

$C(k)$ Carga no tempo k , ou seja, na hora atual.

$C(k-1)$ Carga no tempo $(k-1)$, ou seja, na hora anterior.

$C(k-23)$ Carga no tempo $(k-23)$, ou seja, um dia atrás da hora cuja carga será prevista.

$C(k-167)$ Carga no tempo $(k-167)$, ou seja, uma semana atrás da hora cuja carga será prevista.

$C(k-191)$ Carga no tempo $(k-191)$, ou seja, uma semana e um dia atrás da hora cuja carga será prevista.

$HS(k+1)$ Hora-seno no tempo $(k+1)$, ou seja, hora-seno da hora cuja carga será prevista

$HC(k+1)$ Hora-cosseno no tempo $(k+1)$, ou seja, hora-cosseno da hora cuja carga será prevista

ou seja :

(k) = é a hora atual

$(k+1)$ = é a hora da carga a ser prevista.

$$HS(k+1) = \text{sen}(2\pi.\text{hora}/24)$$

$$HC(k+1) = \text{cos}(2\pi.\text{hora}/24)$$

Os dados de entrada representam uma série temporal. Séries temporais, como o próprio nome já diz, são observações organizadas em um espaço de tempo. Em nosso dia a dia podemos citar alguns, tais como:

- Consumo de energia mensal em uma residência ou em uma empresa.
- Consumo de água mensal.
- Mudanças de preço em produtos de consumo em uma semana.
- Etc.

Observações de dados passados contém informações que podem caracterizar seu padrão de comportamento no futuro, assim, representamos as duas últimas unidades de entrada através de funções periódicas como o seno e o co-seno, com a intenção de reforçar a periodicidade dos dados de entrada que representam as cargas elétricas.

4.3 - O Modelo neural hierárquico

O modelo neural apresentado aqui é uma extensão do mapa auto-organizável de Kohonen, ele possui integradores de tempo, que são aplicados nas unidades de entrada. Estes integradores representam um dos parâmetros da rede, que são responsáveis por determinar o tamanho da memória que se pode ter em relação a cargas elétricas passadas, assim, com uma melhor “lembrança” do passado, o modelo pode ter um melhor “conhecimento” do futuro.

A grande maioria de propostas de aplicações de redes neurais em previsão de carga, faz uso do “Multilayer Perceptron”, com algoritmo backpropagation.

Neste trabalho utilizamos este modelo (figura 4.1) com a intenção de verificar se ele seria capaz de atender nossas expectativas, utilizando-se como entrada outros tipos de conjuntos dados, diferentes daqueles utilizados quando ele foi implementado e que é abordado na literatura [8-13].

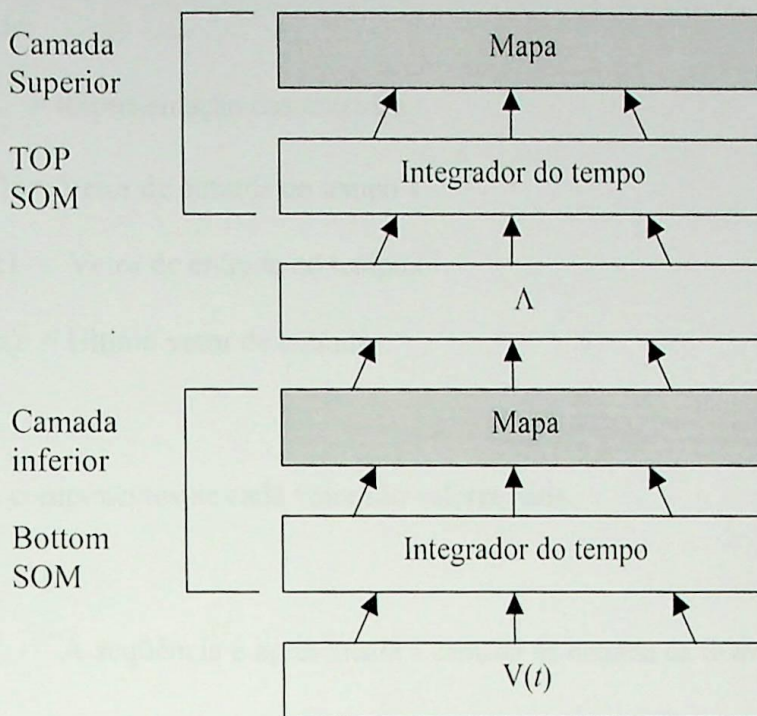


Figura 4.1 - O Modelo neural hierárquico

O modelo utiliza dois mapas auto-organizáveis (self-organizing maps – SOMs), um sobre o outro.

A entrada para o modelo é uma seqüência no tempo de vetores com N dimensões, representados por S, ou seja:

$$S_1 = V(1), V(2), \dots, V(t), \dots, V(z) \quad (2)$$

onde:

S_1 = Representação das entradas

$V(1)$ = Vetor de entrada no tempo 1

$V(t)$ = Vetor de entrada no tempo t

$V(z)$ = Último vetor de entrada.

Os componentes de cada vetor são valores reais.

A seqüência é apresentada à camada de entrada da SOM inferior (bottom SOM), um vetor de cada vez. A camada de entrada tem N unidades, uma para cada componente do vetor de entrada $V(t)$, e um integrador de tempo. A ativação $X(t)$ das unidades na camada de entrada é dada então por:

$$X(t) = V(t) + \delta_1 X(t-1) \quad (3)$$

onde:

$\delta_1 \in (0, 1)$ é a taxa de decaimento

Para cada vetor de entrada $X(t)$, a unidade vencedora $i^*(t)$ no mapa é a unidade que tem a menor distância $\psi(i,t)$. Para cada unidade de saída i , $\psi(i,t)$ é dada pela distância euclidiana entre o vetor de entrada $X(t)$ e o vetor de pesos da unidade W_i .

Cada unidade de saída i na vizinhança $N^*(t)$ da unidade vencedora $i^*(t)$ tem seus pesos W_i atualizados por:

$$W_i(t+1) = W_i(t) + \alpha Y(i)[X(t) - W_i(t)] \quad (4)$$

Onde $\alpha \in (0,1)$ é a taxa de aprendizagem. $Y(i)$ é a *função de interação da vizinhança*, uma função gaussiana, dada por:

$$Y(i) = k_1 + k_2 e^{-\frac{k_3[\phi(i,i^*(t))]^2}{2\sigma^2}} \quad (5)$$

Onde k_1 , k_2 e k_3 são constantes, σ é o raio da vizinhança $N^*(t)$, e $\Phi(i,i^*(t))$ é a distância no mapa entre a unidade i e a unidade vencedora $i^*(t)$. A distância $\Phi(i',i'')$ entre duas unidades quaisquer i' e i'' no mapa é calculada de acordo com a norma do máximo,

$$\Phi(i',i'') = \max\{|t' - t''|, |c' - c''|\} \quad (6)$$

onde:

$|t' - t''|$ - São as coordenadas da unidade i' no mapa

$|c' - c''|$ - São as coordenadas da unidade i'' no mapa

A entrada para a SOM superior do modelo é determinada pelas distâncias $\Phi(i, i^*(t))$ das n unidades no mapa da SOM inferior. A entrada é assim uma seqüência no tempo de vetores n -dimensionais,

$$S_2 = \Lambda\Phi(i, i^*(1)), \Lambda\Phi(i, i^*(2)), \dots, \Lambda\Phi(i, i^*(t)), \dots, \Lambda\Phi(i, i^*(z)) \quad (7)$$

onde:

Λ é uma *função de transferência* n -dimensional em um domínio do espaço n -dimensional.

Λ é definido como:

$$\Lambda(\Phi(i, i^*(t))) = \begin{cases} 1 - k\Phi(i, i(t)) & \text{if } i \in N^*(t) \\ 0 & \text{otherwise} \end{cases} \quad (8)$$

Onde k é um valor constante e positivo, e $N^*(t)$ é uma vizinhança da unidade vencedora.

A seqüência S_2 é então apresentada à camada de entrada da SOM superior, um vetor de cada vez. A camada de entrada tem n unidades, uma para cada componente do vetor de entrada $\Lambda\Phi(i, i^*(t))$, e um integrador de tempo. A ativação $X(t)$ das unidades na camada de entrada é então dada por:

$$X(t) = \Lambda(\Phi(i, i^*(t))) + \delta_2 X(t-1) \quad (9)$$

onde:

$\delta_2 \in (0,1)$ é a taxa de decaimento.

O método de treinamento utilizado na camada superior (top SOM) é idêntico ao método utilizado na camada inferior (bottom SOM), gerando-se as previsões (cargas previstas).

Testes e Resultados Obtidos Utilizando o Modelo Neural Hierárquico Para previsão de carga em sistemas de potência

1.1 - Introdução

Neste capítulo, são apresentados os resultados obtidos com o modelo proposto no capítulo 4. O modelo é aplicado a um sistema de potência real, com o objetivo de prever a carga de potência. Os resultados são comparados com os obtidos com o modelo de referência.

CAPÍTULO 5

Testes e Resultados Obtidos Utilizando o Modelo Neural Hierárquico Para previsão de carga em sistemas de potência

5.1 – Introdução

Neste capítulo, são apresentados dois experimentos, realizados com o modelo descrito no capítulo 4. Cada experimento compreende sete estudos, cada qual referente a um dia da semana. Os resultados dos dois primeiros experimentos se diferenciam, devido a

diferentes ajustes de parâmetros do modelo. Para uma melhor visualização, os resultados obtidos são apresentados em gráficos, comparando a carga prevista com a carga real, além de tabelas mostrando os erros entre as cargas reais e previstas.

5.2 - Objetivos dos experimentos

O modelo de Rede Neural utilizado neste trabalho foi inicialmente desenvolvido e aplicado em sequências musicais e são descritos na literatura [12,13]. Para atender à proposta deste trabalho, foram desenvolvidas representações para os dados, bem como ajustes nos parâmetros do modelo.

Os experimentos apresentados aqui, têm, portanto, como objetivo principal, verificar se o modelo se revela eficaz no tratamento das sequências de cargas, de modo a produzir previsões de carga elétrica satisfatórias.

5.2.1 – Realização dos estudos

Para realização dos sete estudos de cada experimento, foram utilizados 1704 padrões de carga, que serviram tanto para o conjunto de treinamento quanto para o de teste. Os conjuntos de treinamento e testes bem como os padrões de carga a serem previstos pelo modelo são descritos em 7 estudos.

1. Estudo 1

Conjunto de treinamento e teste: Padrões de cargas de 361 a 1536 – 1176 padrões

Previsão a ser fornecida pelo modelo: Cargas de 1537 a 1560 – 24 padrões

Dia da previsão: Sexta feira

2. Estudo 2

Conjunto de treinamento e teste: Padrões de cargas de 385 a 1560 – 1176 padrões

Previsão a ser fornecida pelo modelo: Cargas de 1561 a 1584 – 24 padrões

Dia da previsão: Sábado

3. Estudo 3

Conjunto de treinamento e teste: Padrões de cargas de 409 a 1584 – 1176 padrões

Previsão a ser fornecida pelo modelo: Cargas de 1585 a 1608 – 24 padrões

Dia da previsão: Domingo

4. Estudo 4

Conjunto de treinamento e teste: Padrões de cargas de 433 a 1608 – 1176 padrões

Previsão a ser fornecida pelo modelo: Cargas de 1609 a 1632 – 24 padrões

Dia da previsão: Segunda Feira

5. Estudo 5

Conjunto de treinamento e teste: Padrões de cargas de 457 a 1632 – 1176 padrões

Previsão a ser fornecida pelo modelo: Cargas de 1633 a 1656 – 24 padrões

Dia da previsão: Terça Feira

6. Estudo 6

Conjunto de treinamento e teste: Padrões de cargas de 481 a 1656 – 1176 padrões

Previsão a ser fornecida pelo modelo: Cargas de 1657 a 1680 – 24 padrões

Dia da previsão: Quarta feira

7. Estudo 7

Conjunto de treinamento e teste: Padrões de cargas de 505 a 1680 – 1176 padrões

Previsão a ser fornecida pelo modelo: Cargas de 1681 a 1704 – 24 padrões

Dia da previsão: Quinta feira

5.2.2 – Experimento 1

O objetivo do experimento é prever a demanda de carga elétrica, de hora em hora, durante um período de 24 horas. Como mencionado anteriormente, os dados de entrada foram extraídos de uma concessionária elétrica brasileira. Os dados foram representados de acordo com a representação descrita no quarto capítulo.

O treinamento das duas camadas do modelo, bottom SOM e top SOM, foi realizado em duas fases, mapeamento grosseiro e refinamento. Na fase de mapeamento grosseiro, a taxa de aprendizado e o raio da vizinhança foram reduzidos linearmente, enquanto que na fase de refinamento, foram mantidos constantes. As SOMs inferior e superior foram treinadas e testadas respectivamente com mapas de tamanho 15x15 em 700 épocas, e 18x18 em 850 épocas. As taxas de decaimento para os integradores das SOMs inferior e superior foram de 0,5 e 0,8 respectivamente. Os pesos iniciais foram dados aleatoriamente a ambas as SOMs.

O experimento compreendeu sete estudos. Em cada estudo, uma rede foi treinada para prever, de hora em hora, a carga de um dia específico da semana. O primeiro experimento previu a carga de uma sexta-feira, e assim sucessivamente, até o sétimo experimento, que previu a carga de uma quinta-feira.

As figuras 5.1 a 5.7 apresentam os gráficos comparativos entre as cargas previstas pelo modelo e as cargas reais consumidas no período. A tabela 5.1 apresenta a porcentagem do erro, bem como o erro médio para cada estudo.

5.2.2.1 - Estudo 1

Conjunto de treinamento: Padrões de cargas de 361 a 1536 – 1176 padrões

Previsão obtida: Cargas de 1537 a 1560 – 24 padrões

Dia da previsão: Sexta-feira

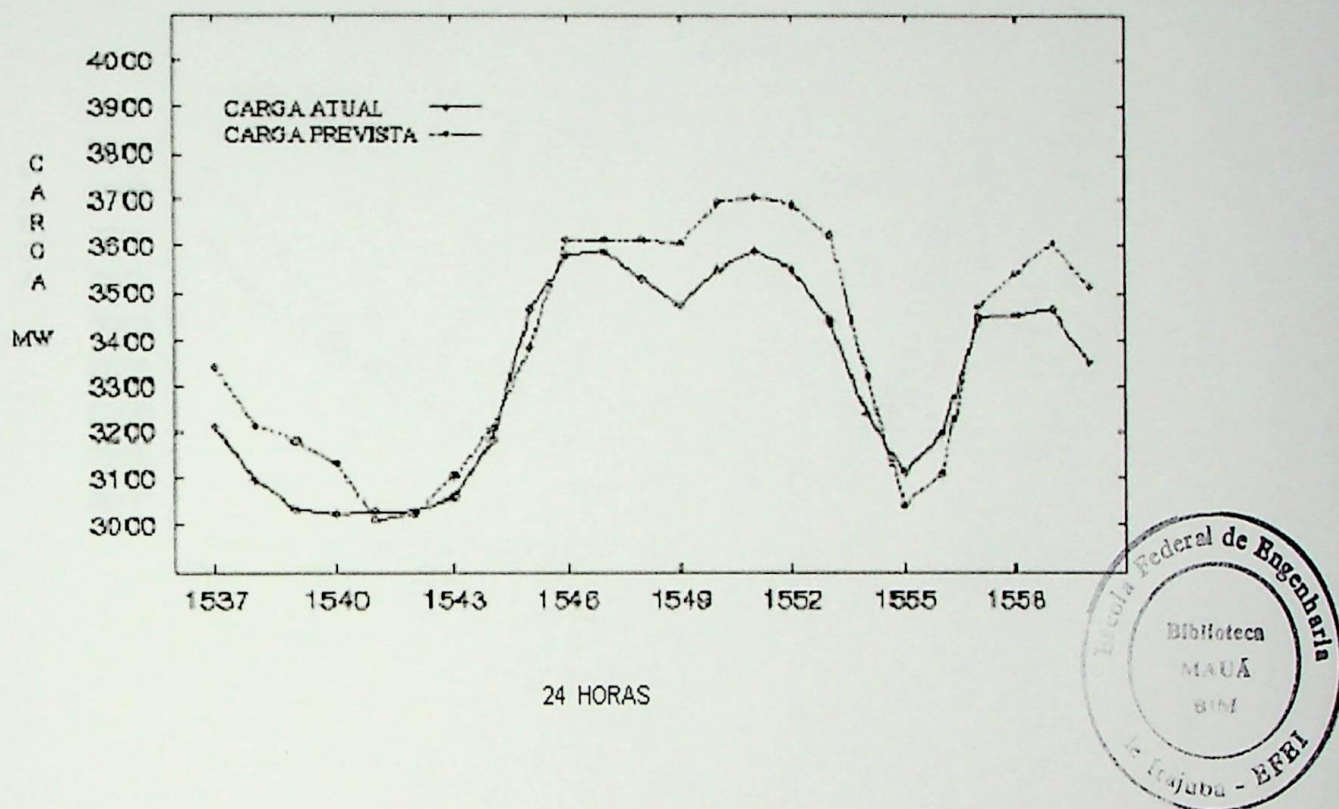


Figura 5.1 – Resultado da comparação entre a carga prevista e a carga real de uma sexta-feira.

5.2.2.2 - Estudo 2

Conjunto de treinamento: Padrões de cargas de 385 a 1560 – 1176 padrões

Previsão obtida: Cargas de 1561 a 1584 – 24 padrões

Dia da previsão: Sábado




Figura 5.2 – Resultado da comparação entre a carga prevista e a carga real de um sábado

5.2.2.3 - Estudo 3

Conjunto de treinamento: Padrões de cargas de 409 a 1584 – 1176 padrões

Previsão obtida: Cargas de 1585 a 1608 – 24 padrões

Dia da previsão: Domingo

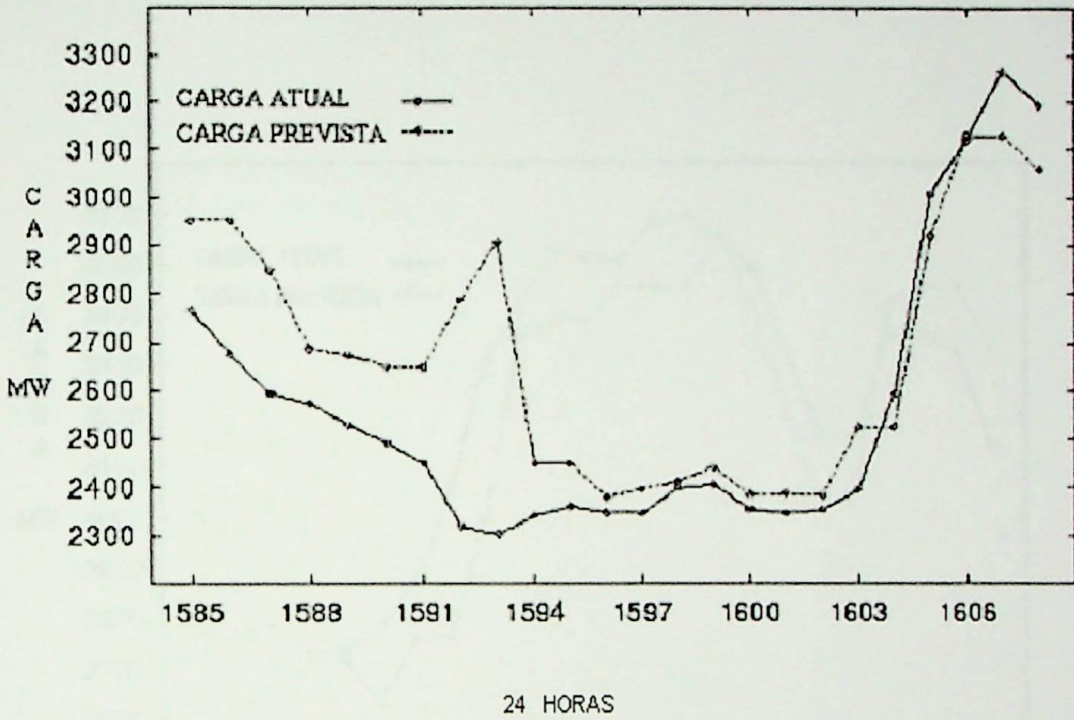


Figura 5.3 – Resultado da comparação entre a carga prevista e a carga real de um domingo

5.2.2.4 - Estudo 4

Conjunto de treinamento: Padrões de cargas de 433 a 1608 – 1176 padrões

Previsão obtida: Cargas de 1609 a 1632 – 24 padrões

Dia da previsão: Segunda-Feira




Figura 5.4 – Resultado da comparação entre a carga prevista e a carga real de uma segunda-feira

5.2.2.5 - Estudo 5

Conjunto de treinamento: Padrões de cargas de 457 a 1632 – 1176 padrões

Previsão obtida: Cargas de 1633 a 1656 – 24 padrões

Dia da previsão: Terça-Feira




Figura 5.5 – Resultado da comparação entre a carga prevista e a carga real de uma terça-feira

5.2.2.6 - Estudo 6

Conjunto de treinamento: Padrões de cargas de 481 a 1656 – 1176 padrões

Previsão obtida: Cargas de 1657 a 1680 – 24 padrões

Dia da previsão: Quarta-feira




Figura 5.6 – Resultado da comparação entre a carga prevista e a carga real de uma quarta-feira

5.2.2.7 - Estudo 7

Conjunto de treinamento: Padrões de cargas de 505 a 1680 – 1176 padrões

Previsão obtida: Cargas de 1681 a 1704 – 24 padrões

Dia da previsão: Quinta-feira





Figura 5.7 – Resultado da comparação entre a carga prevista e a carga real de uma quinta-feira

5.2.2.8 - Tabela de erros

HORAS	Estudos						
	I	II	III	IV	V	VI	VII
1	4,04	4,83	6,81	-8,01	4,09	9,46	11,01
2	3,77	5,03	10,43	-3,41	8,13	17,1	12,97
3	4,86	5,15	9,84	-1,21	-1,46	9,28	6,82
4	3,58	2,96	4,42	-0,73	-1,77	6,37	6,64
5	-0,65	-1,72	5,65	-0,77	-2,13	6,42	5,68
6	-0,21	2,56	6,28	-5,46	-0,72	5,74	6,17
7	1,47	4,25	8,15	-4,15	-2,98	-0,51	2,21
8	0,76	10,21	20,22	-9,6	-0,43	2,63	-0,28
9	-2,26	21,24	26,23	-9,08	-1,31	-5,71	1,15
10	0,94	22,47	4,63	-1,75	-1,75	1,11	0,32
11	0,74	6,64	3,73	-3,98	-1,9	0,63	0,71
12	2,37	23,63	1,33	-3,51	-1,02	1,08	0,77
13	3,9	15,66	2,15	-1,42	1,04	2,44	2,37
14	4,01	20,59	0,6	-3,66	3,54	3,95	2,17
15	3,19	17,17	1,48	-3,9	0,9	6,45	1,15
16	3,89	23,58	1,3	0,19	0,63	5,12	3,48
17	5,36	23,28	1,72	-2,15	1,86	1,69	0,39
18	2,49	7,38	1,29	-4,06	-6,11	0,17	-2,02
19	-2,24	1,35	5,42	-4,02	-1,85	2,48	-0,57
20	-2,74	2,01	-2,62	-3,48	-1,81	-1,07	0,99
21	0,75	6,58	-2,94	1,76	2,19	2,78	-1,45
22	2,77	6,87	0,27	2,92	-1,24	6,75	-2,69
23	4,12	13,24	-4,15	3,93	6,38	8,79	4,12
24	4,89	17,4	-4,2	6,17	8,3	11,43	4,65
Média do erro	2,75	11,07	5,66	3,72	2,65	4,99	3,37

Tabela 5.1 – Tabela de erros dos estudos do primeiro experimento

Os valores apresentados nesta tabela se referem ao erro, em porcentagem, entre a carga real e a carga prevista, das 24 horas dos 7 dias de uma semana. O último campo apresenta a média dos valores absolutos dos erros.

5.2.2.9 - Análise dos resultados dos estudos do experimento 1

Os resultados dos estudos são promissores, eles demonstram que a utilização de outros conjuntos de dados como entrada não alteram o processamento da rede, confirmando que o modelo pode atuar em outras áreas, sem modificações dos algoritmos de processamento interno. Outro fator que também confirma esta afirmação é a mudança de comportamento da rede em alterações sensíveis de alguns parâmetros, como foi o caso dos integradores de tempo, neste experimento a previsão foi melhor nas últimas horas. Contudo, para as previsões nas primeiras horas, o desempenho do modelo foi fraco. Uma maior investigação sobre os efeitos dos integradores de tempo se faz necessária para se produzir uma melhor adaptabilidade.

Dentre os estudos, é possível ter ocorrido a situação onde uma unidade no mapa que não tenha respondido a qualquer padrão de carga durante a fase de treinamento, fora requisitada a responder a um padrão particular durante a fase da previsão. Isso produziu efeitos altamente indesejáveis, apesar desta ocorrência ter sido rara. As setas no gráfico da figura 5.2 indicam os pontos onde isto ocorreu. A rede passava a produzir previsões muito ruins, e não mais se recuperava. Uma estratégia deve ser planejada para evitar tal situação.

Dados de carga contínuos foram empregados como entrada para o modelo em todos os estudos. Estes dados, contudo, deveriam ter sido refinados de forma a incluir somente os dados pertinentes a cada estudo. Por exemplo, para prever, de hora em hora, as cargas de uma segunda-feira, foram empregados dados de carga contínuos, incluindo aqueles de todos os dias da semana. Assim, a rede foi treinada com dados irrelevantes, uma vez que

padrões de carga normalmente variam consideravelmente de um dia para o próximo. Acreditamos que o refinamento dos dados de entrada melhorará o desempenho geral do modelo.

5.2.3 – Experimento 2

Tal como do primeiro experimento, o objetivo deste segundo experimento também é prever a demanda de carga elétrica, de hora em hora, durante um período de 24 horas. Os dados de entrada foram os mesmos utilizados no primeiro experimento e foram representados de acordo com a representação descrita no quarto capítulo.

O treinamento das duas SOMs do modelo foi realizado de forma idêntica ao treinamento do modelo no primeiro experimento. As SOMs inferior e superior foram treinadas e testadas respectivamente com mapas de tamanho 15x15 em 700 épocas, e 18x18 em 850 épocas.

As taxas de decaimento foram diferentes das utilizadas no primeiro experimento. Neste, utilizamos taxas de decaimento de 0,4 e 0,7 para os integradores das SOMs inferior e superior respectivamente. Os pesos iniciais foram dados aleatoriamente a ambas as SOMs.

O experimento compreendeu sete estudos. Em cada estudo, uma rede foi treinada para prever, de hora em hora, a carga de um dia específico da semana. O primeiro experimento previu a carga de uma sexta-feira, e assim sucessivamente, até o sétimo experimento, que previu a carga de uma quinta-feira.

As figuras 5.8 a 5.14 apresentam os gráficos comparativos entre as cargas previstas pelo modelo e as cargas reais consumidas no período. A tabela 5.2 apresenta a porcentagem do erro, bem como o erro médio para cada estudo.



Figura 5.7 - Resultado de comparação entre as cargas previstas e reais.

5.2.3.1 - Estudo 1

Conjunto de treinamento: Padrões de cargas de 361 a 1536 – 1176 padrões

Previsão obtida: Cargas de 1537 a 1560 – 24 padrões

Dia da previsão: Sexta-feira




Figura 5.8 - Resultado da comparação entre a carga prevista e a carga real de uma sexta-feira

5.2.3.2 - Estudo 2

Conjunto de treinamento: Padrões de cargas de 385 a 1560 – 1176 padrões

Previsão obtida: Cargas de 1561 a 1584 – 24 padrões

Dia da previsão: Sábado




Figura 5.9 - Resultado da comparação entre a carga prevista e a carga real de um sábado

5.2.3.3 - Estudo 3

Conjunto de treinamento: Padrões de cargas de 409 a 1584 – 1176 padrões

Previsão obtida: Cargas de 1585 a 1608 – 24 padrões

Dia da previsão: Domingo

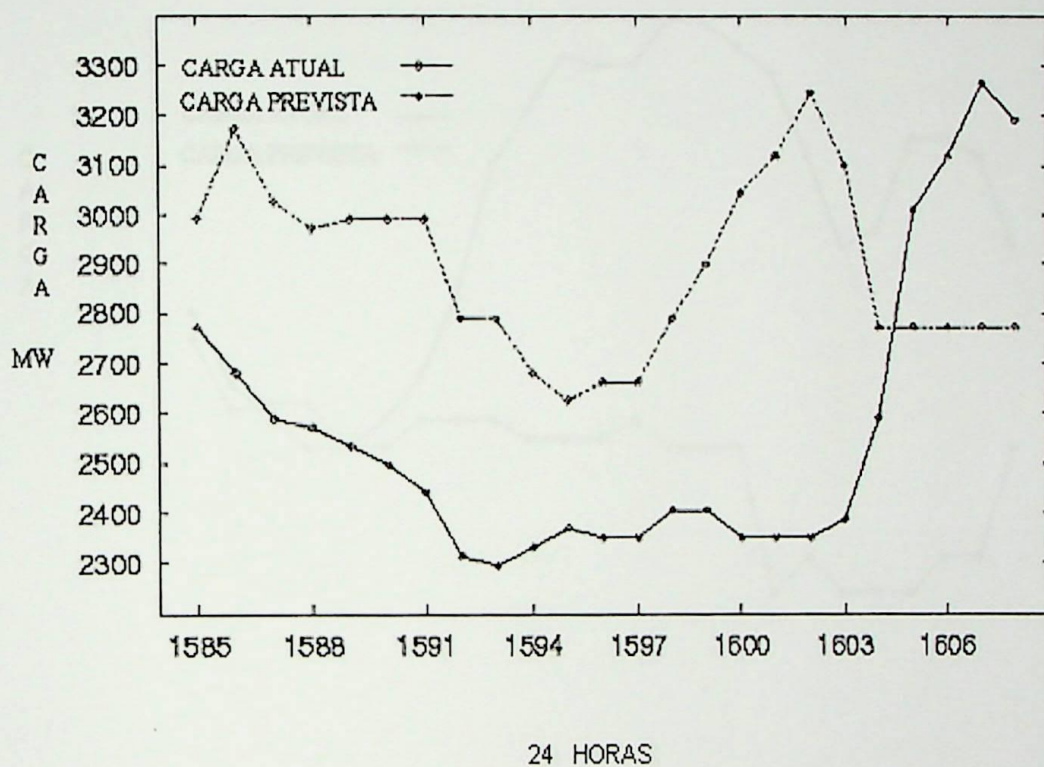


Figura 5.10 - Resultado da comparação entre a carga prevista e a carga real de um domingo

5.2.3.4 - Estudo 4

Conjunto de treinamento: Padrões de cargas de 433 a 1608 – 1176 padrões

Previsão obtida: Cargas de 1609 a 1632 – 24 padrões

Dia da previsão: Segunda-Feira




Figura 5.11 - Resultado da comparação entre a carga prevista e a carga real de uma

segunda-feira

5.2.3.5 - Estudo 5

Conjunto de treinamento: Padrões de cargas de 457 a 1632 – 1176 padrões

Previsão obtida: Cargas de 1633 a 1656 – 24 padrões

Dia da previsão: Terça-Feira




Figura 5.12 - Resultado da comparação entre a carga prevista e a carga real de uma terça-feira

5.2.3.6 - Estudo 6

Conjunto de treinamento: Padrões de cargas de 481 a 1656 – 1176 padrões

Previsão obtida: Cargas de 1657 a 1680 – 24 padrões

Dia da previsão: Quarta-feira

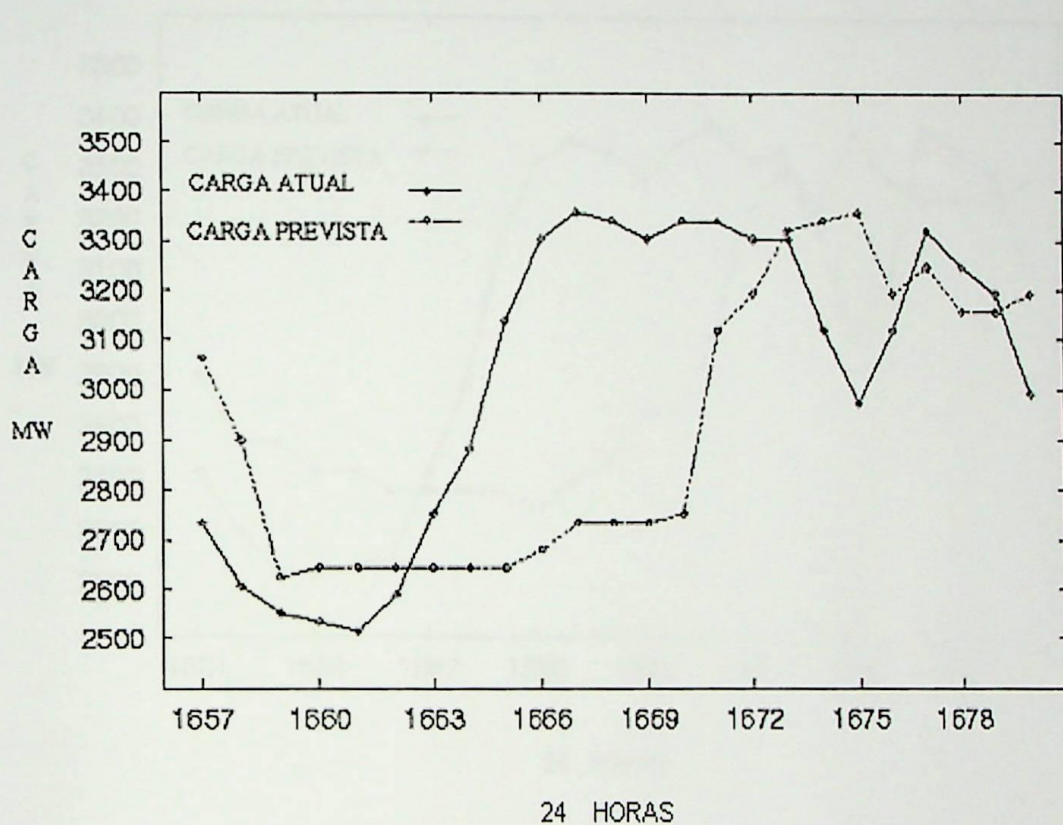


Figura 5.13 - Resultado da comparação entre a carga prevista e a carga real de uma quarta-feira

5.2.3.7 - Estudo 7

Conjunto de treinamento: Padrões de cargas de 505 a 1680 – 1176 padrões

Previsão obtida: Cargas de 1681 a 1704 – 24 padrões

Dia da previsão: Quinta-feira




Figura 5.14 - Resultado da comparação entre a carga prevista e a carga real de uma quinta-feira

5.2.3.8 – Tabela de erros

HORAS	ESTUDOS						
	I	II	III	IV	V	VI	VII
1	1,71	2,86	7,92	-1,82	0,00	12,04	6,73
2	-1,18	-1,78	18,43	-1,92	1,31	11,23	6,31
3	2,42	-1,82	16,96	1,31	0,68	2,87	9,38
4	0,60	2,49	15,65	3,34	-0,67	4,33	8,00
5	-0,60	3,78	18,05	0,00	0,00	5,09	7,22
6	-0,60	4,44	19,77	-1,97	-1,34	2,12	5,02
7	-6,57	7,82	22,47	-3,17	-7,67	-3,99	-1,35
8	-9,80	9,24	20,55	-8,41	-12,16	-8,25	-6,98
9	-17,41	7,12	21,51	-15,51	-19,04	-15,74	-15,56
10	-19,94	5,75	14,90	-19,30	-21,98	-18,83	-20,38
11	-20,35	3,17	10,81	-21,81	-23,05	-18,52	-19,61
12	-19,22	5,18	13,23	-21,41	-22,22	-18,08	-18,08
13	-17,94	7,16	13,23	-20,36	-20,93	-17,17	-13,92
14	-19,02	6,47	15,96	-23,91	-19,28	-17,53	-15,26
15	-15,77	14,52	20,53	-23,91	-9,86	-6,57	-12,40
16	-12,34	17,39	29,56	-22,73	-8,77	-3,32	-3,75
17	-5,30	22,52	32,67	-29,91	1,69	0,55	-1,10
18	2,25	27,98	38,12	-24,24	5,25	7,04	1,73
19	11,73	22,74	29,88	-22,15	13,54	12,92	13,54
20	9,17	15,67	7,07	-23,05	12,01	2,35	6,53
21	-1,06	10,09	-7,90	-27,24	4,51	-2,20	-4,31
22	-1,06	10,74	-11,14	-25,06	6,30	-2,82	-2,74
23	-1,58	12,76	-15,12	-24,24	7,53	-1,15	-1,66
24	1,63	17,03	-13,18	-12,83	16,20	6,73	5,28
Média dos erros	8,30	10,02	18,11	15,82	9,83	8,39	8,58

Tabela 5.2 – Tabela de erros dos estudos do segundo experimento

Os valores apresentados nesta tabela se referem ao erro, em porcentagem, entre a carga real e a carga prevista, das 24 horas dos 7 dias de uma semana. O último campo apresenta a média dos valores absolutos das cargas.

5.2.3.9 - Análise dos resultados dos estudos do experimento 2

Os resultados deste experimento são igualmente promissores, pelas mesmas razões descritas em 5.2.2.9. Este, porém, ao contrário do primeiro, apresentou bons resultados nas previsões de demanda de carga nas primeiras horas. Contudo, para previsões nas últimas horas, o desempenho do modelo foi deficiente. Este comportamento confirmou as nossas expectativas. Baixas taxas de decaimento reduzem o tamanho da memória para eventos passados [8-13], e isto parece ser crítico para previsões em amplos horizontes de tempo. Aqui também uma melhor investigação sobre os efeitos dos integradores de tempo se faz necessária para produzir uma melhor adaptabilidade do modelo ao problema de previsão de carga.

Os mesmos dados de carga contínuos usados no primeiro experimento também foram empregados como entrada para o modelo em todos os estudos deste segundo experimento. Como mencionado anteriormente no primeiro experimento, estes dados deveriam ter sido refinados de forma a incluir somente os dados pertinentes a cada estudo. Acreditamos que o refinamento dos dados de entrada melhorará o desempenho geral do modelo.

CAPÍTULO 6

Conclusão



6.1 – Sumário

A previsão de carga a curto prazo tem um papel fundamental no planejamento de operações econômicas, confiáveis e seguras para o sistema elétrico. A precisão das previsões de carga elétrica tem efeitos consideráveis na operação de sistemas elétricos de potência e nos custos de produção de energia.

Os operadores do sistema elétrico devem prever quais serão os padrões de carga no futuro próximo, em um período de 24 horas, de forma a prover o sistema com geração suficiente para atender a demanda. Para tal, o operador deve manter no sistema níveis suficientes de reserva de energia, a fim de minimizar os impactos das incertezas contidas nas previsões.

O custo operacional para manter-se tais níveis de reserva de energia é alto, posto que as unidades que compõem as reservas estão sub-utilizadas e usualmente operando bem abaixo de suas possibilidades. Desta forma, reduzindo-se a margem de erro das previsões, reduzem-se, outrossim, os níveis de reserva de energia e por conseguinte, os custos operacionais, sem afetar, contudo, a confiabilidade e a segurança do sistema.

Métodos convencionais e não-convencionais têm surgido para auxiliar o processo de previsão de cargas. Métodos convencionais, em geral, são métodos baseados em modelos estatísticos. A previsão baseia-se nos valores anteriores de carga ou erros anteriores de previsão.

Este trabalho se baseou na utilização de um método não convencional que tem se destacado bastante em previsão de cargas elétricas em sistema de potência, conhecido por Redes Neurais. A modelagem do problema de previsão de carga elétrica por Redes Neurais tem alcançado êxito, devido, sobretudo, ao seu inerente tratamento não-linear das séries temporais de demandas anteriores de cargas elétricas, a sua robustez no tratamento das correlações existentes entre as variáveis envolvidas e a sua plasticidade.

Esta dissertação apresentou a aplicação de um modelo neural hierárquico na previsão de cargas elétricas em sistemas de potência. O modelo neural hierárquico é composto por dois mapas de Kohonen (SOMs), dispostos um sobre o outro. O modelo tem como uma de suas principais características uma memória ajustável para eventos ocorridos no passado. Esta memória, ou ainda, este conhecimento do passado, permite que o modelo produza previsões consistentes do futuro.

Foram realizados dois experimentos, cada qual contendo sete estudos. Os resultados de ambos os experimentos são promissores.

No primeiro experimento, obtivemos bons resultados para previsões de demanda de carga nas últimas horas. Contudo, para as previsões nas primeiras horas, o desempenho do modelo foi pobre. No segundo experimento, obtivemos bons resultados para previsões nas primeiras horas. Para previsões nas últimas horas, entretanto, o desempenho do modelo foi deficiente. Uma melhor investigação sobre os efeitos dos integradores de tempo se faz necessária para produzir uma melhor adaptabilidade do modelo ao problema de previsão de carga.

6.2 - Propostas para trabalhos futuros

Algumas propostas podem ser citadas com vistas à melhoria de desempenho do modelo. São elas:

- Desenvolver uma estratégia para evitar a situação que ocorre quando uma unidade no mapa que não tenha respondido a qualquer padrão de carga durante a fase de treinamento seja requisitada a responder a um padrão particular durante a fase da previsão. A ocorrência desta situação foi rara durante os testes, embora tenha produzido efeitos indesejáveis, conforme comentado no quinto capítulo.
- Refinar os dados de entrada para que incluam somente dados de carga pertinentes a cada estudo. Conforme mencionado no quinto capítulo, a rede foi treinada com dados tanto relevantes quanto irrelevantes para o problema em questão. Acreditamos que o refinamento dos dados de entrada melhorará o desempenho geral do modelo.
- Realizar um estudo mais aprofundado sobre os integradores de tempo do modelo. Acreditamos que tal estudo nos leve a uma acentuada melhoria nas previsões do modelo.

- Submeter o problema de previsão de carga, com estes mesmos dados de carga reais utilizados nesta dissertação, ao multilayer perceptron. Compara-se, assim, o desempenho dos dois modelos sobre o mesmo conjunto de dados de entrada.
- Utilizar, como dados de entrada, não somente valores de cargas elétricas, mas também outras variáveis, tais como, temperatura e/ou velocidade do vento, dentre outras.

REFERÊNCIAS BIBLIOGRÁFICAS

- [1] Z. L. KOVÁCS – “Redes Neurais Artificiais”, Fundamentos e aplicações, 2^a. Edição Revisada e ampliada. Editora Collegium Cognitio - 1996.
- [2] Z. L. KOVÁCS – “O cérebro e a sua mente”, Uma introdução à Neurociência Computacional. Edição Acadêmica - 1997.
- [3] G.GROSS & F.D. GALIANA, - “Short term load forecasting”, Proc IEEE, Vol 75, No. 12 - 1987
- [4] G. LAMBERT TORRES & A.P. ALVES DA SILVA – “Aplicação de Sistemas Inteligentes em Engenharia de Potência”, Controle e Automação, Vol 5 - 1994.
- [5] J. A. B. MONTEVECHI – “Redes Neurais”, uma introdução e sua utilização na formação de famílias de peças, EFEI - 1998.
- [6] E. C. DE BARROS CARVALHO FILHO, T. B. LUDERMIR, W. R. DE OLIVEIRA JÚNIOR & F. G. FRANÇA – “Modelagem, Aplicações e Implementações de Redes Neurais”, I congresso Brasileiro de Redes Neurais - 1994.
- [7] G. ANTÔNIO AUGUSTO – “Redes Neurais Artificiais”, Uma abordagem revolucionária em inteligência artificial. Revista Micro Sistemas, edição 133 e edição 134, ano XII.

[8] O. A. S. CARPINTEIRO, A. P. ALVES DA SILVA & C. H. L. FEICHAS – “A Hierarchical Self-Organizing Map Model in Short-Term Load Forecasting”, International Joint Conference on Neural Networks - (IJCNN), Como, Italy - 2000

[9] – O. A. S. CARPINTEIRO & A. P. ALVES DA SILVA – “A Hierarchical Self-Organizing Map Model in Short-Term Load Forecasting”, Vth International Conference on Engineering Applications of Neural Networks (EANN), Warsaw, Poland - 1999

[10] – O. A. S. CARPINTEIRO & A. P. ALVES DA SILVA – “A Hierarchical Neural Model to Short-Term Load Forecasting”, IV Congresso Brasileiro de Redes Neurais, ITA - 1999.

[11] – O. A. S. CARPINTEIRO & A. P. ALVES DA SILVA – “A Hierarchical Self-Organizing Map Model in Short-Term Load Forecasting”, VIth Brazilian Symposium on Neural Networks, Brazil - 2000

[12] – O. A. S. CARPINTEIRO – “A Hierarchical Self-Organizing Map Model for Sequence Recognition”, In L. Niklasson, M Bodén, and T. Ziemke, editors, Proceedings of International Conference on Artificial Networks 98, Skövde, Sweden - 1998.

[13] – O. A. S. Carpinheiro. A hierarchical self-organizing map model for pattern recognition. In L. Caloba and J. Barreto, editors, Proceedings of the Brazilian Congress on Artificial Neural Networks 97 (CBRN 97), Brazil - 1997.

[14] – D. Niebur. State-of-the-art overview on artificial neural networks in power systems. In M. El Sharkawi and D. Niebur editors, *Introduction to Concepts in Artificial Neural Networks*. IEEE Power Engineering Society - 1996.

[15] –D. Niebur. State-of-the-art overview on artificial neural networks in power systems. In M. El Sharkawi and D. Niebur editors, *An Example of Unsupervised Networks Kohonen's Self-organizing Feature Map*. IEEE Power Engineering Society - 1996.

[16] – M. A. El-Sharkawi. State-of-the-art overview on artificial neural networks in power systems. In M. El Sharkawi and D. Niebur editors, *Neural Network and its Ancillary Techniques as Applied to Power Systems*. IEEE Power Engineering Society - 1996.

[17] – H. Mori. State-of-the-art overview on artificial neural networks in power systems. In M. El Sharkawi and D. Niebur editors, *A tutorial Course on Artificial Neural Networks with Applications to Power Systems*. IEEE Power Engineering Society - 1996.

[18] – T. Dillon, S. Sestilo, A.Piras & T. Czernichow. State-of-the-art overview on artificial neural networks in power systems. In M. El Sharkawi and D. Niebur editors, *Short Term Load Forecasting: the International Activities*. IEEE Power Engineering Society - 1996.

[19] – A. J.Vander, J. H. Sherman & D. S. Luciano – “Fisiologia Humana” – McGraw Hill

- [20] – W. S. McCulloch & W. H. Pits, “A logical calculus of the ideas immanent in nervous activity”, “Bulletin of Mathematical Biophysics” - 1943.
- [21] – R. P. LIPPMAN – “An Introduction to Computing with Neural Nets”, IEEE ASSP Magazine - 1987
- [22] – S. Haykin – “Redes Neurais” – Princípios e Práticas. 2ª. Edição. Editora Bookman. Porto Alegre - 2001
- [23] - K. Gurney – “Neural Nets”
<http://www.shef.ac.uk/psychology/gurney/notes/contents.html>
- [24] – Kohonen, T., Self-Organization and Associative Memory, 3rd ed., Springer-Verlag - 1989 .
- [25] – Beale, R & Jackson, T., Neural Computing: An Introduction, Adam Hilger - 1991
- [26] – L. R. Medsker - “Hybrid Intelligent Systems” , Department of Computer Science and Information Systems. The American University, Kluwer Academic Publishers, Boston/Dordrecht/London - 1995.

[27] – Furnas Centrais Elétricas S.A., EFEI (Escola Federal de Engenharia de Itajubá) & FUPAI (Fundação de Pesquisa e Assessoramento a Indústria) – “Métodos de previsão de carga a curto prazo”, 2^o Relatório Técnico.

[28] – G. Gross & F. D. Galiana, - “Short term load forecasting”, Proc. IEEE, Vol. 75 - 1987.

[29] - G. Lambert Torres, L. E. Borges da Silva, B. Valiquette, H. Greiss & D. Mukhedkar, - “A fuzzy Knowledge-Based System for Bus Load Forecasting”, Fuzzy Logic Technology and Applications, por Robert J. Marks II, IEEE Press - 1994.

[30] – I. Moghram, S. Rahman, - “Analysis and Evaluation of Five Short-Term Load Forecasting Techniques”, IEEE. Trans on Power Systems, Vol. 4 - 1989.

[31] - A. D. Papalexopoulos & C. T. Hesterberg, - “A regression based approach to short-term system load forecasting”, IEEE Trans on Power Systems, Vol 5 - 1999.

[32] – W. R. Christiaanse, - “Short-term load forecasting using General Exponential Smoothing”, IEEE. Trans. Power App. Syst., Vol. PAS-90, No. 2 - 1971

[33] – H. Shidl – “C completo e Total”, Makron Books, 3^a. Edição - 1997.

[34] – C. Hare, E. Dulaney & G. Eckel – “Inside UNIX”, Riders Publishing - 1994.