

AVALIAÇÃO DO DESEMPENHO DAS REDES NEURAIS ARTIFICIAIS NA IDENTIFICAÇÃO DE SÍTIOS SEM E COM PERDA DE INSERÇÃO, MEDIANTE PARÂMETROS CLÍNICOS*

EVALUATION PERFORMANCE OF ARTIFICIAL NEURAL NETWORK IN THE IDENTIFICATION OF PERIODONTAL SITES WITHOUT AND WITH ATTACHMENT LOSS, BASED ON CLINICAL PARAMETERS

Marly Kimie SONOHARA

Professora Assistente do Departamento de Odontologia da Universidade Estadual de Maringá e aluna do Curso

Sebastião Luiz Aguiar GREGHI

Professor Assistente da Disciplina de Periodontia da FOB-USP

Aguinaldo CAMPOS JÚNIOR

Professor Livre-Docente da Disciplina de Periodontia da FOB-USP

*Dissertação apresentada à FOB-USP, para obtenção do grau de Mestre em Periodontia de Pós-graduação em Periodontia, a nível de Mestrado pela FOB-USP

Recebido para publicação em 21/11/97

A avaliação do desempenho das Redes Neurais (RN) na identificação de sítios periodontais sem (SPI) e com perda de inserção (CPI) baseou-se nas observações clínicas de uma amostra de 2701 sítios de 19 indivíduos monitorados por um período de 18 meses. Os dados referentes às medidas sequenciais do nível de inserção relativo foram analisados pelos métodos estatísticos de tolerância e regressão para a determinação de sítios SPI e CPI. Os seis parâmetros clínicos (sítio, dente, nível de inserção inicial, idade, sexo e fumo) considerados variáveis *input*, e os resultados estatísticos, representando a variável *output*, foram aplicados à RN nos Modelo Tolerância (MT) e Modelo Regressão (MR). As variáveis *input* e *output* de 2188 sítios foram utilizadas na fase de treinamento da RN. Em seguida, somente as variáveis *input* dos 513 sítios restantes foram apresentadas à rede na fase teste, para verificar o seu treinamento. Os resultados evidenciaram a possibilidade de aplicação das RN em Periodontia para identificar sítios SPI (alta especificidade), a partir de uma amostra representativa.

Unitermos: Redes neurais artificiais; Doença periodontal, diagnóstico.

INTRODUÇÃO

Os parâmetros clínicos (presença de placa, vermelhidão, supuração, sangramento à sondagem, profundidade de bolsa, nível de inserção e perda dentária) empregados para a monitorização da destruição periodontal passada têm sido imprecisos na determinação da atividade da doença periodontal presente ou futura^{11,17}. Inicialmente, as medidas clínicas de avaliação da doença periodontal eram expressas em valores médios de vários índices (Índice Periodontal e de Doença Periodontal) de doença periodontal, sem permitirem uma estimativa das diferenças entre sítios de um mesmo indivíduo e entre indivíduos de uma população. Por meio dessas análises, estabeleceu-se o conceito da progressão da doença como lenta, contínua e universal. Isso talvez tenha ocorrido pelo fato dos parâmetros utilizados representarem medidas estáticas da doença.

As observações clínicas baseadas em avaliações longitudinais da perda de inserção em indivíduos não tratados levaram à teoria da progressão da doença periodontal em surtos de destruição seguidos por longos períodos de quiescência^{8,10,11,12,13,18}. Através dessas medidas seqüenciais, definiu-se a severidade da doença como variando consideravelmente dentro da cavidade bucal, e constatou-se uma proporção relativamente pequena de indivíduos em uma população, concentrando a maior parte da destruição periodontal e perda dentária¹⁴.

A doença periodontal representa uma combinação de fatores externos, como virulência dos espécimes bacterianos; locais, compreendendo a resistência específica do hospedeiro às agressões exógenas; e gerais, relacionados à somatória das condições intrínsecas do indivíduo, como desordens sistêmicas, distúrbios imunológicos, predisposição genética, senescência e outros. Isso claramente explica a distribuição heterogênea da doença periodontal entre as diferentes populações, ou seja, alguns indivíduos ou grupos são mais ou menos susceptíveis em relação a outros, e exigem para isso terapias periodontais e medidas preventivas diferenciadas⁸. A identificação precoce desses grupos representa o principal objetivo dos métodos diagnósticos, possibilitando o controle e tratamento da doença periodontal⁸.

A partir da complexidade biológica da condição periodontal e da ausência de um modelo matemático preciso para descrição e análise da evolução da doença, observou-se a necessidade da utilização de meios adequados de medição da atividade destrutiva, associados a recursos tecnológicos de computação, tanto para a

análise de uma grande quantidade de dados clínicos periodontais dos sítios e indivíduos, como para a obtenção de informações rápidas e confiáveis. Este trabalho procurou empregar sistemas de processamento de informações, denominados Redes Neurais, para auxiliarem na identificação de sítios sem e com perda de inserção, mediante parâmetros clínicos rotineiramente utilizados na prática clínica.

As Redes Neurais Artificiais, ou simplesmente, Redes Neurais (RN), uma das aplicações de maior interesse e avanço nas pesquisas da Inteligência Artificial, foram inspirados inicialmente no conhecimento estrutural e funcional do cérebro humano, e na capacidade dos neurônios biológicos de processarem as informações¹⁶. Os seus componentes e atividades (aprendizagem, treinamento, memorização, e outras) são denominadas de acordo com a similaridade neurobiológica². A estrutura das RN consiste de unidades básicas de processamento difusoras de impulsos, denominadas neurônios (neurônios artificiais)^{7,16}, organizados em subgrupos denominados camadas ou campos¹⁶. Os modelos de RN podem apresentar uma, duas, três ou mais camadas. Na primeira camada, denomina-se entrada ("input") e a última, saída ("output"). Os modelos com três ou mais camadas apresentam uma ou mais destas localizadas entre a primeira e a última, designadas de camadas intermediárias ("hidden"). Todos os neurônios *input* estão conectados a todos os neurônios *hidden* e estes, por sua vez, a todos os neurônios *output*³, através de conexões. A definição de um peso (w) a cada conexão representa uma parte essencial da capacidade de memória^{2,16} e conhecimento da RN¹⁶.

A forma de organização e arranjo dos neurônios na rede e o tipo de conexão estabelecido entre eles constituem a arquitetura particular dos modelos de RN¹⁶. Cada neurônio *input* recebe uma informação (entrada X) sob a forma de valor binário (0 e 1) ou bipolar (1 e -1), distribuindo-a para os neurônios da próxima camada^{16,8,2}. Se a soma ponderada dessas entradas ($\sum w.X$) for maior que o valor limiar q (valor de corte), o neurônio (*hidden/output*) será ativado. Caso contrário, não ocorrerá a sua ativação^{7,16}.

A função de transferência determina o valor da saída do neurônio ativado, baseando no valor total de suas entradas^{3,16}.

O processo de aprendizagem em RN, corresponde ao ajuste dos valores dos pesos das conexões entre neurônios de modo a modificar o comportamento da rede. Portanto, aprendizagem significa criar um sistema com um determinado comportamento, da mesma forma como

ocorre nos seres humanos. Por exemplo, crianças são clogiadas quando realizam adequadamente uma tarefa, são censuradas quando atravessam a rua sem olhar para os lados. Na aprendizagem da criança, há um reforço dos bons comportamentos e há uma repressão dos maus. De forma análoga, se a rede produz uma saída errada, deve-se reduzir as chances de sua nova ocorrência, e se a saída for correta, então não se faz nada⁷. Assim, o princípio geral, consiste em fazer o neurônio aprender a partir de seus erros. As regras ou algoritmos de aprendizagem foram desenvolvidas para o aprendizado supervisionado⁷ e sua aplicação à rede denomina-se de fase de treinamento.

O primeiro passo para a estruturação das RN corresponde à escolha do fenômeno a ser interpretado, e o segundo, ao seu processo de modelação. Esta etapa representa a seleção de critérios/parâmetros que definem ou descrevem corretamente o fenômeno e suas codificações. Na formulação de um modelo do fenômeno, emprega-se dois componentes importantes: variável *input*, representando as características clínicas ou laboratoriais, e variável *output*, a condição final do fenômeno. Essas variáveis podem ser descritas na forma de um vetor, denominado vetor modelo, e ao conjunto denomina-se de modelo ou conjunto de treinamento.

Cada uma das variáveis *input* selecionadas corresponde a um neurônio na camada de entrada, sendo seus dados apresentados na forma numérica. Neste caso, emprega-se números inteiros e crescentes para maior simplicidade da rede. Por exemplo, um neurônio *input*, figurando uma variável qualitativa, como sexo, pode ser codificado em dois valores binários: 0, para representar um gênero, e 1, para representar o outro. Mas existem outras formas de configurar esses dados: a variável sexo pode ser indicada por dois neurônios *input* com valor binário 0 e 1: um neurônio para indicar a presença ou ausência do gênero feminino e outro neurônio para indicar a presença ou ausência do gênero masculino. No caso de uma saída da rede, representada por um neurônio *output*, tem-se um valor 0 para um diagnóstico (por exemplo, ausência de doença) e 1 para o diagnóstico oposto (por exemplo, presença de doença)³. A variável *output* pode também ser representada por dois neurônios *output*.

Um conjunto de treinamento com todos os vetores modelos representando a maioria das possíveis combinações das variáveis, ou seja, a representatividade do fenômeno, com dados padronizados, promoverá o treinamento adequado da rede. Esse conjunto corresponde cerca de 80% do banco de dados. Na fase de treinamento, apresenta-se aos neurônios *input* da camada de entrada

cada um desses vetores modelos. Calcula-se, então, a saída, baseada na soma ponderada das entradas e na função de transferência, obtendo-se o resultado final da rede³.

A cada apresentação de um vetor modelo, denominado de ciclo, a rede estima uma saída para ser comparada ao resultado real. Se o resultado estiver dentro da tolerância do erro, apresenta-se as variáveis do próximo exemplo³. A obtenção de um erro maior implicará na modificação dos pesos e na nova apresentação do padrão a ser ensinado. A repetição deste processo ocorrerá até a convergência da rede, uma propriedade essencial de um regra de aprendizagem¹⁶.

Com o término do treinamento, os pesos são fixados e a rede pode resolver, de modo satisfatório, problemas parecidos com os do conjunto de treinamento. A esta propriedade denomina-se de generalização¹⁶. Para isso, um conjunto de dados (vetores testes) são apresentados à rede na fase teste, contendo apenas as informações das variáveis *input*. Os valores das variáveis *output* serão determinadas pela rede treinada, reconhecendo esses novos vetores a partir da sua capacidade de generalização²³. O conjunto teste utilizado nessa fase compreende os 20% restantes da amostra, incluindo apenas os dados das variáveis *input* a serem reconhecidos, buscando-se a resposta da rede a novos conjuntos de dados desconhecidos. A estimativa da rede é comparada ao resultado real, obtendo-se a sua capacidade de prever o *output* de um padrão não apresentado previamente à rede³.

MATERIAL E MÉTODOS

A amostra utilizada neste trabalho consistiu de 19 indivíduos (9 mulheres e 10 homens, com idade média de 36 anos) com doença periodontal, apresentando no mínimo 2 dentes com profundidade de sondagem ≥ 5 mm e 1 sítio com nível de inserção ≥ 4 mm à sondagem manual. A obtenção das medidas longitudinais do nível de inserção relativo foi padronizada pela utilização da Florida Probe®, uma sonda eletrônica de força constante com armazenamento automático computadorizado dos dados, e de placas oclusais individualizadas. Estas placas foram confeccionadas em plástico termossensível com 2,0mm de espessura, em máquina de vácuo (Plastvac p5, Bio-art) sobre modelos de gesso pedra. Nestas placas, foram realizados degraus, como pontos de referência fixos, utilizando ponta diamantada cilíndrica nº 61 (CA 3a, KG-Sorensen) para contra-ângulo, para padronizar o posicionamento e angulação da sonda nas regiões

proximais e centrais dos dentes, durante a medida do nível de inserção¹⁵.

A peça manual da sonda utilizada foi a Stent Probe®, caracterizada por um batente, cujo aro apoiou-se no degrau confeccionado na placa oclusal. A ponta afeta da sonda apresentou 20mm de comprimento e 0,4mm de diâmetro. A sondagem foi realizada em seis sítios por dente (mésio-vestibular, centro-vestibular, disto-vestibular, mésio-lingual, centro-lingual e disto-lingual), com uma força constante de 20 gramas, executada pelo mesmo examinador (experiente) nos períodos de *baseline*, 6, 12 e 18 meses. Os dados de 2701 sítios foram analisados pelos métodos estatísticos de tolerância e regressão para estabelecer alterações no nível de inserção relativo, classificando-os em sítios sem e com perda de inserção.

Para a estruturação da RN, foi utilizado um programa de RN com quatro camadas, aiNet 1.22, sendo uma de entrada, duas intermediárias e uma de saída. O fenômeno clínico a ser analisado pela RN relacionou-se à alteração do nível de inserção relativo de 2701 sítios após um período de monitorização de 18 meses. No total, 2188 sítios foram escolhidos aleatoriamente para o treinamento da RN (vetores modelos) e os 513 sítios restantes (mais ou menos 20%), para a fase teste (vetores testes). Cada vetor modelo (vm) representou uma maneira de descrever e codificar uma condição clínica - alteração da medida do nível de inserção de cada sítio - através de seus dois componentes, variáveis *input* e variáveis *output*. Os parâmetros clínicos selecionados como variáveis *input* e codificados para a descrição de cada sítio foram idade, sexo, fumo, sítio, dente e nível de inserção inicial à sondagem manual. Cada variável representou um neurônio na camada de entrada. A alteração na medida do nível de inserção relativo estabelecida pelo método de tolerância ao final do 4º. exame, correspondeu à variável *output*. A análise estatística das medidas do nível de inserção relativo possibilitou a criação de dois modelos de treinamento da RN: Modelo Tolerância (MT), utilizando como variável *output* os resultados obtidos pelo método de tolerância; e o Modelo Regressão (MR), os resultados obtidos pelo método de regressão.

A apresentação dos 2188 vetores modelos à RN, em todos os modelos estabelecidos, correspondeu à fase de treinamento. Nesta fase, através do processo iterativo, a rede aprendeu por exemplos, modificando os pesos para reduzir os erros e obter a saída desejada¹⁷. Após esta etapa, avaliou-se a capacidade da RN treinada de reconhecer os novos conjuntos de dados (fase teste). Foram apresentados à rede um conjunto de 513 vetores testes, sem variável

output. A estimativa da rede de detectar sítios sem ou com perda de inserção a partir de um conjunto de dados desconhecidos foi comparada ao *output* real. Os *output* da rede foram dicotomizados em valores 0 e 1, mediante a definição de um valor de corte de 0,5. Os valores do *output* obtidos pela rede $\geq 0,5$ foram considerados com perda de inserção (valor 1), enquanto aqueles $< 0,5$, sem perda de inserção (valor 0). Os resultados obtidos nessa fase foram comparados àqueles determinados pela análise estatística (*output* real).

RESULTADOS

TABELA 1 - Distribuição dos sítios SPI e CPI da amostra empregada na RN, para os Modelos Tolerância (MT) e Regressão (MR), em números absolutos e percentuais

Sítios	SPI	CPI	Total
MT	2362 (87,45%)	339 (12,55%)	2701
MR	2641 (97,78%)	60 (2,22%)	2701

TABELA 2 - Distribuição dos sítios SPI e CPI empregados na RN, durante a fase de treinamento e teste, para os Modelos Tolerância e Regressão, em números absolutos e percentuais

FASE	Modelo Tolerância		Modelo Regressão		Total
	SPI	CPI	SP	CPI	
Treinamento	1926 (88,03%)	262 (11,97%)	2136 (97,62%)	52 (2,38%)	2188
Teste	436 (84,99%)	77 (15,01%)	505 (98,44%)	8 (1,56%)	513

TABELA 3 - Distribuição dos sítios SPI e CPI classificados corretamente pela RN na fase teste, para os Modelos Tolerância (MT) e Regressão (MR), em números absolutos e percentuais

Sitio	Modelo	
	MT	MR
SPI	436 (100%)	505 (100%)
CPI	0 (0%)	0 (0%)

DISCUSSÃO

Os sítios identificados com perda de inserção após 18 meses corresponderam àqueles com aumento estatisticamente significativo no nível de inserção relativo, determinado pela análise das medidas longitudinais através dos métodos estatísticos. Teoricamente, os métodos de tolerância e regressão são capazes de reduzir o efeito do erro de reprodutibilidade^{5,12}. Um número maior de sítios com perda de inserção foi determinado pelo método de tolerância comparado à regressão, representando 12,55% (339 sítios) e 2,22% (60 sítios) do total da amostra, respectivamente (Tabela 1).

Segundo AINET¹, observa-se uma relação entre o número de variáveis e o número de vetores modelos não determinada analiticamente; um número maior de variáveis requer um número maior de vetores modelos durante o processo de modelação. A regra pode parecer insignificante, mas a prática mostra a existência de muitos problemas, quando se deseja modelar um fenômeno para o qual não existem dados suficientemente adequados. Durante o preparo do banco de dados, a certeza da representatividade dos vetores modelos e também, a confiabilidade das medidas, representam aspectos importantes na estruturação das RN.

No Modelo Tolerância (MT), observa-se o número de sítios com perda de inserção representando 11,97% (262 sítios) do conjunto de vetores modelos (2188 sítios) (Tabela 2). O conjunto de treinamento foi representativo para os casos dos sítios sem perda de inserção (1926 sítios), confirmado pelo resultado obtido pela RN na fase teste. A rede conseguiu detectar todos os sítios sem perda de inserção (especificidade=1) no MT, sem registrar nenhum sítio com perda de inserção (sensibilidade=0) (Tabela 3).

Na fase de treinamento, os vetores modelos referentes aos sítios com perda de inserção foram mais restritos para o MR, cerca de 52 sítios (2,38%) (Tabela 2). Isso revela um conjunto de treinamento representativo para os casos de sítios sem perda de inserção (2136), pois a rede conseguiu prever todos os sítios sem perda de inserção (especificidade 1) no MR, na fase teste (Tabela 3). O valor da sensibilidade igual a 0 representa os 8 sítios com perda de inserção não identificados pela RN (sensibilidade 0) (Tabela 3). Neste caso, a quantidade e a qualidade da amostra contendo sítios com perda de inserção foi provavelmente inadequada e não homogênea.

Um problema básico observado nos MT e MR foi o tamanho do banco de dados disponível, com número limitado de sítios com perda de inserção. O modelo

preparado a partir de um número limitado de vetores modelos pode gerar baixa previsão, levando à conclusão de ineficácia do modelo, uma vez que a fase teste corresponde ao cálculo dos valores da variável *output* (desconhecido) do vetor teste, baseado em todos os vetores modelos já apresentados à RN na fase de treinamento. Estudos epidemiológicos^{14,15} têm demonstrado uma baixa prevalência de sítios com perda de inserção, num mesmo indivíduo e numa população.

A medição do nível de inserção relativo realizada com a sonda computadorizada de força constante, placa oclusal com marcações e calibração do examinador em todos os exame minimizaram os erros inerentes ao método; pois quanto maior o erro, maior a dificuldade em determinar a sua associação a outra variável¹¹. Apesar desse cuidado, não foi possível determinar qualquer relação das variáveis *input* com a *output*, nos MT e MR. Possivelmente, a associação de certos índices clínicos com o quadro de progressão da doença periodontal seja melhor definida num período maior de monitorização longitudinal (superior a 2 anos), dando aos sinais clínicos da doença um valor diagnóstico significativo, como sugerido por BADERSTEN; NILVÉUS; EGELBERG¹⁶.

A utilização desses parâmetros clínicos não permitiram a detecção de sítios com perda de inserção, provavelmente pela falta de aquisição de conhecimento sobre o fenômeno durante o treinamento da rede, e não pelo processo de modelação inadequado. Em analogia ao cérebro humano, isso significaria: um raciocínio seria mais correto quanto maior ou melhor as informações sobre o fenômeno a ser analisado, e isto não foi observado com a amostra dos sítios com perda de inserção.

CONCLUSÕES

A RN foi capaz de identificar todos os sítios sem perda de inserção e nenhum sítio com perda de inserção nos MT e MR, a partir de parâmetros clínicos selecionados. Dessa forma, a possibilidade de aplicação das RN em Periodontia está relacionada à representatividade da amostra, como demonstrado pelos altos valores de especificidade.

ABSTRACT

The evaluation of performance of Neural Network (NN) in the identification of periodontal sites without (WOAL) and with attachment loss (WAL) based on the clinical observations from a sample of 2701 sites from 19

individuals was monitored during a period of 18 months. The data regarding longitudinal measure evaluation of the relative attachment level measurements were analyzed by tolerance and regression statistical methods for determination of sites WOAL and WAL. The six clinical parameters (site, tooth, initial attachment level, age, gender and tobacco), considered input variables, and the statistical results, representing the serving as output variable, were applied to NN in the Tolerance (TM) and Regression Models (RM). Firstly, the input and output variables from 2188 sites were used in the training step of NN. Then, the input variables information of 513 remaining sites, without output variable, were presented to NN in the test step, to verify its training. The results evidenced the possibility of application of NN in Periodontics to identify sites WOAL (high specificity), from a representative sample.

UNITERMS: Artificial neural network; Periodontal disease, diagnosis

REFERÊNCIAS BIBLIOGRÁFICAS

1- INET: a neural network application for 32 bit Windows environment - version 1.20. Slovenia, s.ed., 1996.

2- ALVARAGER, T.; SMITH, T.J.; VIJAI, F. The use of artificial neural networks in biomedical technologies: an introduction. **Biomedical instrumentation & technology**, v.28, n.4, p.315-22, July/Aug. 1994.

3- ASTION, M.L.; WILDING, P. The application of backpropagation neural networks to problems in pathology and laboratory medicine. **Arch. Path. Lab. Med.**, v.116, n.10, p.995-1001, Oct. 1992.

4- BADERSTEN, A.; NILVÉUS, R.; EGELBERG, J. Effect of nonsurgical periodontal therapy. VII. Bleeding, suppuration and probing depth in sites with probing attachment loss. **J. clin. Periodont.**, v.12, n.6, p.432-40, July 1985.

5- BADERSTEN, A.; NILVÉUS, R.; EGELBERG, J. Effect of nonsurgical periodontal therapy (VIII). Probing attachment changes related to clinical characteristics. **J. clin. Periodont.**, v.14, n.7, p.425-32, Aug. 1987.

6- BADERSTEN, A.; NILVÉUS, R.; EGELBERG, J. Scores of plaque, bleeding, suppuration and probing depth to predict probing attachment loss. 5 years of observation following nonsurgical periodontal therapy. **J. clin. Periodont.**, v.17, n.3, p.102-7, Mar.1990.

7- BEALE, R.; JACKSON, T. **Neural computing: na introduction.** Bristol, Adam Hilger, 1990.

8- CAMPOS JÚNIOR, A. **Identificação de grupos e de modelos matemáticos de risco à doença periodontal.** Bauru, 1992. 175p. Tese (Livre Docência) - Faculdade de Odontologia de Bauru, Universidade de São Paulo.

9- GOODSON, J.M. Clinical measurements of periodontitis. **J. clin. Periodont.**, v.13, n.5, p.446-55, May 1986.

10- GOODSON, J.M. et al. Patterns of progression and regression of advanced destructive periodontal disease. **J. clin. Periodont.**, v.9, n.6, p.472-81, Nov./Dec. 1982.

11- HAFFAJEE, A.D.; SOCRANSKY, S.S.; GOODSON, J.M. Clinical parameters as predictors of destructive periodontal disease activity. **J. clin. Periodont.**, v.10, n.3, p.257-65, May 1983.

12- HAFFAJEE, A.D.; SOCRANSKY, S.S.; GOODSON, J.M. Comparison of different data analyses for detecting changes in attachment level. **J. clin. Periodont.**, v.10, n.3, p.298-310, May 1983.

13- LINDHE, J.; HAFFAJEE, A.D.; SOCRANSKY, S.S. Progression of periodontal disease in adult subjects in the absence of periodontal therapy. **J. clin. Periodont.**, v.10, n.4, p.433-42, July 1983.

14- LÖE, H. et al. Natural history of periodontal disease in man: the rate of periodontal destruction before 40 years of age. **J. Periodont.**, v.49, n.12, p.607-20, Dec. 1978.

15- MENDONÇA, D.Z. **Monitorização longitudinal da progressão da doença periodontal pela avaliação de alterações no nível de inserção à sondagem, através de sonda computadorizada de força constante.** Bauru, 1996. 172p. Dissertação (Mestrado) - Faculdade de Odontologia de Bauru, Universidade de São Paulo.

16- RAO, V.B.; RAO, H.V. **C++ neural networks and fuzzy logic.** New York, MIS Press, 1993.

17- RYAN, R.J. The accuracy of clinical parameters in detecting periodontal disease activity. **J. Amer. dent. Ass.**, v.11, p.753-60, Nov. 1985.

18- SOCRANSKY, S.S. et al. New concepts of destructive periodontal disease. **J. clin. Periodont.**, v.11, n.1, p.21-32, Jan. 1984.