

# 基于广义回归神经网络的微电路工艺设备表征

游海龙, 贾新章, 张春福

(西安电子科技大学 宽禁带半导体材料与器件教育部重点实验室 陕西 西安 710071)

**摘要:** 为了使用较少的工艺试验建立更高精度的模型描述微电路工艺的复杂性与非线性, 将神经网络技术与统计试验设计相结合代替传统的统计方法应用于微电路热氧化工艺设备的表征. 通过试验设计安排 15 轮试验, 然后基于广义回归神经网络建立了以氧化膜厚以及均匀性为目标值的热氧化工艺模型, 最后利用信噪比函数对模型的拟合以及预测能力进行了验证与比较分析. 结果表明, 该方法建立的模型可用于工艺表征与控制. 所讨论的方法可用于其他微电路工艺设备的表征.

**关键词:** 微电路工艺设备; 广义回归神经网络; 信噪比函数; 试验设计

**中图分类号:** TN305    **文献标识码:** A    **文章编号:** 1001-240X(2005)06-0911-04

## Characterizing the microcircuit process equipment based on the generalized regression neural network

YOU Hai-long, JIA Xin-zhang, ZHANG Chun-fu

(The Ministry of Edu. Key Lab. of Wide Band-Gap Semiconductor Materials and Devices, Xidian Univ., Xi'an 710071, China)

**Abstract:** Because of the complexity and non-linearity of microcircuit processes, the neural network method combined with the design of experiment( DOE ) instead of the traditional statistical methods, is applied to the characterization of thermal oxide layer process equipments. Through only 15 experiments, the model of oxide layer thickness and uniformity is set up based on the generalized regression neural network( GRNN ). The fitness and the predicting capability of the model are discussed using the function of the Signal Noise Ratio ( SNR ). Based on the result, the model can be used to characterize and control the process. The method could also be used for other microcircuit processes.

**Key Words:** microcircuit process equipment; generalized regression neural network; signal noise ratio; design of experiment

开发新的工艺技术、表征和优化现有工艺、减少工艺性能的离散性以提高产品质量和成品率等, 这些都依赖于对特定工艺设备的特性表征, 需要建立工艺设备模型<sup>[1]</sup>. 但是单纯从物理原理出发建立的工艺设备物理模型只能用于工艺原理研究和流程设计, 不能用于实际工艺. 因此, 常采用试验设计、响应曲面设计或者两者的结合等方法开发工艺设备的统计模型. 由于微电路工艺的复杂性与非线性, 为了使用最少的工艺试验建立更高精度的模型, 人们开始将神经网络技术与统计试验设计相结合代替上述方法. 在这些研究中, 可看出基于神经网络的建模方法具有更小的模型误差, 有时即使在较少的试验数据的情况下, 也能获得好的效果.

在已报道的工艺建模文献中, 主要采用 BP( Back-Propagation )网络进行函数逼近<sup>[2,3]</sup>, 它们都是基于较大样本量的基础上的. 并且 BP 网络用于函数逼近时, 都采用负梯度下降法调节权值, 这种权值的调节方法存在着收敛速度慢和局部极小的缺点. 同时在微电路工艺试验中, 基于成本考虑试验样本往往较少( 少于 30 ), 属于小样本建模. BP 网络虽然对试验样本的拟合达到了模型精度的要求, 但是模型的推广能力较差, 因此利用 BP 网络很难取得理想效果. 广义回归网络( GRNN )在一定程度上克服了这些问题, 无论在逼近能力、学习速度以及推广

收稿日期 2004-12-24

基金项目 模拟集成电路国家重点实验室基金资助项目( 51439040103DZ0102 )

作者简介 游海龙( 1979- ), 男, 西安电子科技大学博士研究生.

能力等方面均优于 BP 网络<sup>[3]</sup>. 笔者在探讨微电路工艺中的热氧化工艺炉管的表征时, 将 GRNN 网络与统计试验设计方法结合, 在较少的试验数据下建立了表征热氧化炉管的多输入多输出的设备模型.

## 1 GRNN 神经网络模型结构与函数逼近

在微电路工艺设备表征中, 常面对的是多输入多输出非线性函数的逼近问题. 逼近问题的主导思想是: 充分尊重试验样本, 以拟合精度为建模主要依据, 兼顾网络的推广能力. 以下就函数逼近问题对几种常用网络进行比较分析并介绍广义回归神经网络.

### 1.1 GRNN 与 BP, RBF 网络模型

BP 网络适于函数逼近. 根据 Kolmogorov 定理和 BP 定理, 任一连续函数  $f: U_n \rightarrow R_m, f(X) = Y$ , 可由一个 3 层前向网络来实现, 且可得到任意精度. 为提高 BP 网络的泛化能力要增大网络规模, 而对于具体问题确定何种网络规模并没有理论指导<sup>[4]</sup>. GRNN 网络是径向基(RBF)变化形式, 适于函数逼近, 同样能实现任意非线性函数的任意精度的近似, 其在逼近能力和学习速度方面均优于 BP 网络.

在文献[5]中基于函数逼近的应用中可看到, 针对同一组数据和相同的允许误差, 利用不同的网络进行逼近, 有表 1 所示结果.

表 1 不同网络性能的比较

网络类型	训练时间/s	误差平方和
BP 网络	8.73	$10^{-3}$
径向基函数(RBF)网络	2.75	$10^{-3}$
GRNN 网络	0.37	$10^{-3}$

可看出相对于 BP 网络及 RBF 网络, GRNN 具有较强的函数逼近能力.

### 1.2 GRNN 神经网络模型

GRNN 由一个 RBF 网络层和一个线性网络层组成. RBF 网络是一种性能良好的前向网络, 不仅有全局逼近性质, 而且具有最佳逼近性能. GRNN 网络由 3 层组成: 输入层, RBF 网络层和线性输出层, 其结构如图 1<sup>[6]</sup>. 其中  $R$  为输入向量维数,  $Q$  为该层神经元数,  $dist$ ,  $nprod$  为加权函数,  $W_{k,l}$  为网络的第  $L$  个输入到网络第  $k$  层神经元的连接权值,  $b$  为阈值矢量,  $a$  为输入矢量. 输入层节点只是传递输入信号到隐层. 隐层节点(也称 RBF 节点)由高斯函数构成, 具有局部感知能力. 输出层节点通常是简单的线性函数.

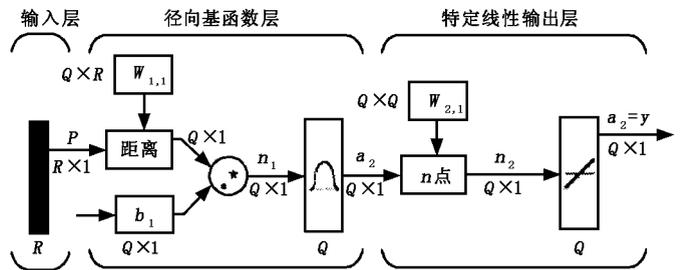


图 1 GRNN 网络结构

## 2 热氧化工艺设备的神经网络模型

氧化工艺是半导体器件和集成电路制造中的基本工艺, 其中热氧化应用最为广泛, 是集成电路制造中生长  $\text{SiO}_2$  膜的主要方法. 本试验的氧化炉管采用  $\text{H}_2, \text{O}_2$  合成方式生长氧化膜, 可同时氧化五舟, 每舟 25 片, 共 125 片晶片. 该工艺考虑的主要是氧化膜厚度以及氧化膜的均匀性. 经过筛选试验, 显著影响膜厚以及均匀性的因素及试验范围为: 氧化温度  $950 \sim 1100^\circ\text{C}$ , 氧化时间  $30 \sim 130 \text{ min}$  以及在一个标准大气压下  $\text{H}_2$  流量  $5.5 \sim 6.5 \text{ L/min}$ , 其他因素(如晶向,  $\text{O}_2$  流量等)不变<sup>[7]</sup>. 因此用于表征该工艺设备的模型有 3 个输入 2 个输出.

### 2.1 试验方案与结果

对于氧化温度、氧化时间以及  $\text{H}_2$  流量, 因为一次线性拟合精度不足, 需要二次项以及交叉项<sup>[7]</sup>. 基于模型的二次项要求, 需要进行响应曲面试验设计. 笔者采用 Box-Behnken 试验设计理论, 只需安排 15 组试验组

合就可满足模型二次拟合要求. 由于试验次数较少, 也符合成本控制要求. 此外, 该方案也与实际操作情况相吻合. Box-Behnken 试验方案与结果如表 2.

表 2 试验方案与试验结果以及网络输出

试验号	温度/℃	时间/min	H <sub>2</sub> 流量/(L · min <sup>-1</sup> )	膜厚	均匀性/(%)
1	950	30	6.0	1.57732	0.73106
2	950	130	6.0	4.39308	0.48766
3	1100	30	6.0	4.70336	0.17572
4	1100	130	6.0	9.84048	0.02957
5	1025	30	5.5	2.91224	0.73935
6	1025	30	6.5	3.07624	0.50056
7	1025	130	5.5	7.06004	0.07792
8	1025	130	6.5	7.67580	0.13601
9	950	80	5.5	3.04068	1.15498
10	1100	80	5.5	7.59760	0.09410
11	950	80	6.5	3.23288	0.55657
12	1100	80	6.5	7.87892	0.09235
13	1025	80	6.0	5.39300	0.20297
14	1025	80	6.0	5.39532	0.14627
15	1025	80	6.0	5.39040	0.34773

注: 基于实际工艺线要求, 这里讨论的试验数据只是相对值, 不影响结论.

### 2.2 热氧化工艺的 GRNN 模型

笔者建立的 GRNN 网络模型由 3 层组成. 第 1 层为输入层, 氧化温度、氧化时间、H<sub>2</sub> 流量; 第 2 层为隐层, 该层神经元数在这里设计为 15 个; 第 3 层为输出层, 为膜厚和均匀性目标值. 其结构如图 2.

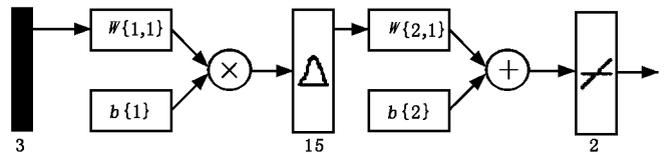


图 2 热氧化工艺的 GRNN 网络结构

基于上述网络结构, 利用表 2 中膜厚以及均匀性样本进行网络训练. 基于样本的预测结果与实际试验结果比较分别如图 3 和图 4 所示. 可看出神经网络具有良好的函数逼近能力.

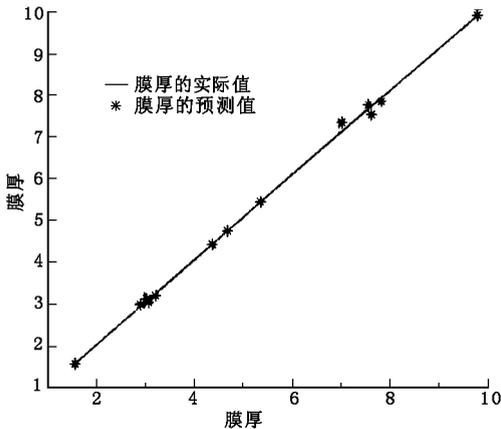


图 3 膜厚实际值与模型预测值比较

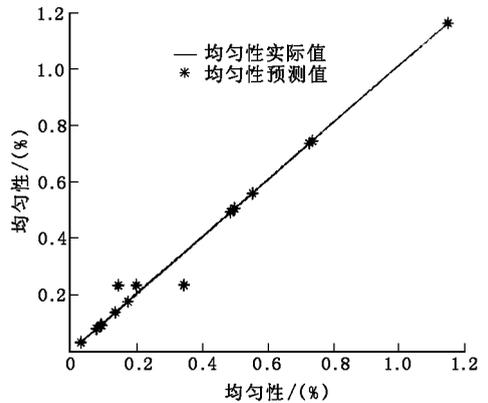


图 4 均匀性实际值与模型预测值比较

利用逼近信噪比来衡量逼近的好坏<sup>[8]</sup>, 信噪比越大表明函数逼近效果越好、预测误差越小.  $S/N = 10 \lg( E_n(d)/E_n(e) )$ , 其中  $E_n(\ )$  表示信号的平方和,  $e$  表示逼近误差,  $e = d - f$ ;  $E_n(d) = \sum_{i=0}^{n-1} d^2$ ;  $E_n(e) = \sum_{i=0}^{n-1} e_i^2$ ; 经过样本训练的 GRNN 膜厚的逼近信噪比  $S/N = 36.2928$  dB, 而均匀性的  $S/N = 14.8125$  dB. 如文献 [8] 所述, 训练样本的逼近信噪比为 20 dB 左右就已经相当好.

### 2.3 模型的推广能力

微电路的工艺设备表征主要用于设备控制与优化,因此需要网络在兼顾训练性能(即数据拟合)的同时具有较好的推广能力,即对训练外数据的预测能力,而不能过于追求其训练性能使对训练外样本的预测能力很差。这里,以膜厚为例讨论模型的预测与推广能力。针对该工艺主要的 5 个规模氧化条件(在训练样本之外)进行了试验,试验膜厚值与模型的预测结果比较如图 5。与基于训练样本的拟合能力相比,模型预测结果存在一定的偏差,但其预测  $S/N = 19.6554$  dB,已经能够满足预测和控制要求,可表征该工艺设备。

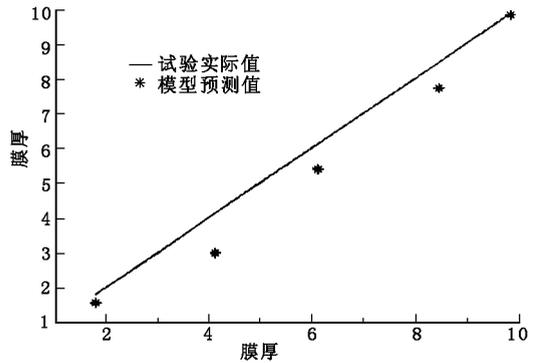


图 5 样本外点氧化膜厚的实际值与预测值比较分析

## 3 结束语

笔者利用 GRNN 表征了微电路的热氧化工艺设备。采用 Box-Behnken 试验设计理论,仅安排了 15 个试验组合就满足了具有非线性特点的设备表征要求。同 BP 网络相比,GRNN 更适用于这种小样本对象的建模。基于该方法建立的神经网络模型已用于氧化工艺控制与优化,同时该方法也可用于其他微电子工艺设备表征。

### 参考文献:

- [1] Lee K K, Bicknell-Tassius R, Dagnall G, et al. Statistical Experimental Design for MBE Process Characterization[ A ]. IEEE/CPMT Int'l Electronics Manufacturing Technology Symposium[ C ]. Austin: IEEE, 1996. 378-385.
- [2] Himmel C D, May G S. Advantages of Plasma Etch Modeling Using Neural Networks Over Statistical Techniques[ J ]. IEEE Trans on Semiconductor Manufacturing, 1993, 6(2): 103-111.
- [3] Kim B, Park G T. Modeling Plasma Equipment Using Neural Networks[ J ]. IEEE Trans on Plasma Science, 2001, 29(1): 8-12.
- [4] Zheng Jianguo, Liu Fang, Jiao Licheng. Use of the Self-adaptation Wavelet Neural Network for Data Mining[ J ]. Journal of Xidian University, 2002, 29(4): 474-476.
- [5] 牛禄,程慧尔,李明辉. 基于神经网络的冷却剂热氧化性拟合方法[ J ]. 推进技术, 2002, 23(2): 132-134.
- [6] Demuth H, Beale M. Neural Network Toolbox for Use with Matlab[ M ]. Boston: The Mathworks Inc, 2003.
- [7] 游海龙,贾新章,徐岚,等. 利用试验设计方法表征微电路工艺设备[ J ]. 微电子学, 2005, 35(4): 382-385.
- [8] 刘荧,林嘉宇,毛钧杰. 基于神经网络的微波电路建模与优化[ J ]. 微波学报, 2000, 16(3): 242-248.

(编辑:郭华)

