

基于模糊小波网络的电力系统短期负荷预测方法

汪新秀, 吴耀武, 熊信银, 黄阿强

(华中科技大学电气与电子工程学院, 湖北 武汉 430074)

摘要: 提出一种基于模糊小波网络的短期负荷预测模型。模糊小波网络结合了小波变换良好的时频局部化性质、模糊推理和神经网络的学习能力, 因此函数逼近能力大大提高。模糊小波网络由一组模糊推理规则和若干小波子网络组成, 其中模糊规则的结论部分与某一特定尺度的小波子网络相对应。在学习过程中通过同时调整小波基函数的平移因子和隶属度函数的形状, 使得模糊小波网络的精度和泛化能力大大提高。实例计算表明, 这种模型是切实可行的。

关键词: 负荷预测; 小波; 模糊小波网络

中图分类号: TM715 **文献标识码:** A **文章编号:** 1003-4897(2004)04-0013-04

0 引言

短期负荷预测是电网经济运行的前提和基础。准确的负荷预测结果, 对电力系统安全可靠运行具有重要意义。许多学者对此进行了深入研究, 并及时地将数学上的最新成果应用到负荷预测领域中去, 使预测水平得到提高, 小波网络便是基于小波分析理论而构成的人工神经网络模型, 它同时具备了小波变换良好的时频局部化性质和神经网络的学习能力, 它既可以在网络结构的确定上有一定的理论指导, 又具有神经网络的许多优秀特性, 并且网络的训练是对特定的凸函数的优化过程, 学习速度比一般网络要快^[1]。

研究表明, 小波网络比神经网络使用的基函数单元更少, 具有更快的收敛速度和更高的精度, 然而小波网络有两个明显的不足: 在多维输入情况下, 学习所用小波基数目过多, 其次是随着网络输入维数的增大, 使得小波网络的收敛速度大大下降, 即不能够解决所谓的“维数灾”问题^[2]。由于影响电力系统短期负荷预测的因素诸多, 本身这又是一个多维输入问题, 基于此, 本文提出了一种将小波网络和模糊神经网络相结合的短期负荷预测的新方法, 利用一组模糊规则将小波网络分为若干小波子网络, 每条模糊规则前提部分将输入样本空间划分为一个局部子空间, 其结论部分则对应某一特定尺度下的小波子网络, 不同尺度下的小波子网络用于捕捉信号的各种不同特性, 将其进行线性组合来逼近信号。它在保证选择一定数量的小波基函数的前提下, 由隶属度函数和小波子网络的输出来精确确定整个网络的输出, 使网络达到最佳逼近, 同时简化了网络的结

构, 避免了小波网络的“维数灾”问题, 提高了计算效率。实践证明该方法具有较高的精度和很强的泛化能力。

1 小波网络

对于输入 $X = [x_1, x_2, \dots, x_q]$, 定义其多维小波母函数为^[2]:

$$(X) = (x_1) (x_2) \dots (x_q) \quad (1)$$

由小波分析理论知, 任一能量有限的信号都有如下离散小波分解形式^[3]:

$$f(X) = \sum_m W^m(X) \quad (2)$$

$$W^m(X) = \sum_n (f, m, n) m, n(X) \quad (3)$$

其中: $W^m(X)$ 为尺度层 m 上的小波分量, n 是尺度层 m 上的小波函数的平移因子。

从式(2)、(3)中不难看出任一信号 $f(X)$ 都可以分解成在不同尺度层 m 上小波分量的线性组合, 这正是我们提出 FWN(模糊小波网络)的出发点。

从理论上来说, 信号的小波展开式的基有无穷多个, 而在分析电力负荷频谱特性时发现, 负荷信号的变化过程具有连续频谱的特性^[4], 负荷预测仅涉及一个频带, 故只需选择最能代表信号信息的主频段来逼近信号。因此在一定精度要求下总可以截取有限小波函数作为基函数, 得:

$$f(X) = \sum_{m_i, n=1}^{N_i} W_{m_i, n} m_i, n(X) \quad (4)$$

其中: $m_i, n = (f, m_i, n)$, m_i, n 分别为所截取的小波函数的尺度及平移因子。这样就可以用一个以小波函数作为激活函数、 $w_{m_i, n}$ 作为从隐含层到输出层的权值的小波神经网络来表示信号 $f(X) \in L^2(R)$ 。在本

文所采用的 FWN 中,为了避免多维小波网络的“维数灾”问题,采用了若干小波子网络,每一小波子网络表示在同一尺度层上的小波分量的线性组合,从而使复杂问题简单化,达到分而治之,结合模糊神经网络将各小波子网络进行线性组合,来逼近信号 $f(X)$,一小波子网络的结构如图 1。

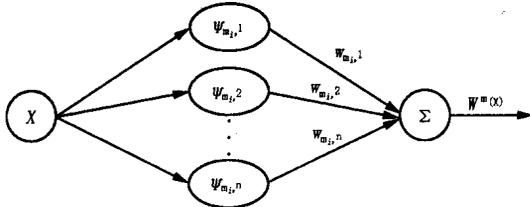


图 1 小波子网络结构

Fig. 1 Sub-network structure of wavelet

由小波理论的多分辨率分析可知,粗尺度层上的小波网络用于捕获信号的全局信息,而较细尺度层上的小波网络用于捕捉信号的各种局部信息,使 FWN 网络具有明确的物理意义,每一小波子网络的规模大大简化,易于进行训练,提高了计算效率的同时也提高了预测精度。

2 模糊小波网络结构

本文采用由 Takigi - Sugeno 改进的模糊推理方法^[5],假定模糊系统有 q 个输入,单个输出 \hat{y} ,其模糊规则有着如下形式:

$$R^i: \text{If } x_1 \text{ is } A_1^i \text{ and } x_2 \text{ is } A_2^i \dots \text{and } x_q \text{ is } A_q^i,$$

$$\text{Then } \hat{y}_i = \frac{\prod_{k=1}^{N_i} w_{m_i, n_k} \mu_{m_i, n_k}(X)}{\sum_{k=1}^{N_i} w_{m_i, n_k} \mu_{m_i, n_k}(X)}, m_i \in Z, n_k \in R^q, w_{m_i, n_k} \in R, X \in R^q \quad (5)$$

其中: R^i 表示第 i ($1 \leq i \leq c$) 条模糊规则; x_j ($1 \leq j \leq q$) 为输入集 X 中的第 j 个变量; N_i 表示第 i 条模糊规则中选用的小波基总数; $n_k = [n_{1k}, n_{2k}, \dots, n_{qk}]$ 为平移因子;而 \hat{y}_i 则是第 i 条模糊规则的输出,其值为具有相同尺度因子 2^{m_i} 小波基的线性组合,本文用一个小波子网络表示,模糊子集 A_j^i 用隶属度函数 $\mu_j^i(x_j)$ 表示, $\mu_j^i(x_j)$ 为高斯型函数:

$$\mu_j^i(x_j) = \exp - \left((x_j - p_{j1}^i) / p_{j2}^i \right)^2 \quad p_{j1}^i, p_{j2}^i \in R \quad (6)$$

其中: p_{j1}^i 和 p_{j2}^i 分别决定隶属函数的中心和宽度。

由模糊推理层得到每条模糊规则对于输入 X 的适用度 $\mu_i(X)$, 实现归一算法得到其激活度 $\hat{\mu}_i(X)$, 它主要是决定了每个小波子网络的输出在整个网络输出中所占的比重:

$$\mu_i(X) = \prod_{j=1}^q \mu_j^i(x_j), \hat{\mu}_i(X) = \mu_i(X) / \sum_{i=1}^c \mu_i(X) \quad (7)$$

其中: $\hat{\mu}_i(X)$ 满足 $0 \leq \hat{\mu}_i(X) \leq 1, \sum_{i=1}^c \hat{\mu}_i(X) = 1$ 。

模糊系统的推理结果为:

$$\hat{y}(X) = \sum_{i=1}^c \mu_i(X) \hat{y}_i(X) / \sum_{i=1}^c \mu_i(X) = \sum_{i=1}^c \hat{\mu}_i(X) \hat{y}_i(X) \quad (8)$$

$$\hat{y}_i(X) = \sum_{k=1}^{N_i} W_{m_i, n_k} \prod_{j=1}^q 2^{-m_i/2} \mu_j^i(2^{m_i} x_j - n_{jk}) \quad (9)$$

在改进的 Takigi - Sugeno 模糊神经网络和小波网络的基础上,式(5) ~ (8)所描述的 FWN 可以用一个多层网络来实现,如图 2 中所示。

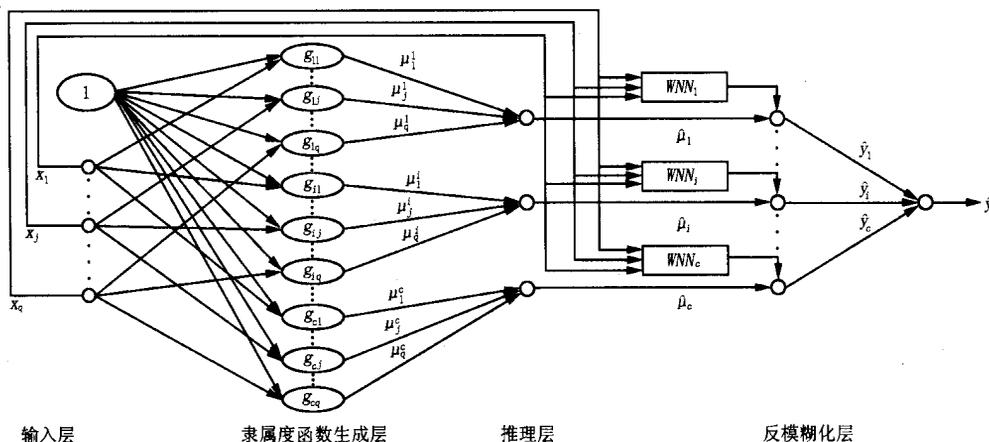


图 2 模糊小波网络结构

Fig. 2 Structure of FWN

该 FWN 由常规的四层模糊神经网络组成,分别为:输入层、隶属度函数生成层、推理层及反模糊化层,各层神经元数目分别为 $q, q \times c, c$ 和 $c+1$, 所以一旦确定输入个数 q 和模糊规则数 c , 模糊小波网络的结构也就确定了, WNN_i 表示第 i 个小波子网络。在隶属度函数生成层中所采用的激活函数是式(6)中给出的高斯型隶属度函数。

本文中采用的 FWN 模型与常规的模糊神经网络模型最大的区别就在于反模糊化层的不同,在模糊神经网络中只能对信号进行局部化逼近,而 FWN 中则采用了一系列小波子网络,它既能对信号进行全局逼近,也能进行局部逼近,而且对于确定模糊规则数有合理的依据,因此,FWN 具有更好的信号逼近能力和更强的适应力。

3 模糊小波网络的学习算法

给定 L 个训练样本对, $X_l (l = 1, 2, \dots, L)$ 表示第 l 个训练样本的输入, y_l 和 \hat{y}_l 分别表示网络的实际输出和目标输出。求解 FWN 的参数采用使 y_l 和 \hat{y}_l 之间误差最小的 BP 算法,其流程如下:

(1) 选择小波基。在本文中选择 Morlet 小波,其表达式为 $\psi(t) = \cos(1.75t) \exp(-\frac{t^2}{2})$, 对样本的输入、输出信号进行时频分析,确定小波函数的平移因子 n_k 及尺度 m_i 。

(2) 初始化网络权值。首先随机产生小波网络的 W_{m_i, n_k} 值,根据式(5)计算得到 $\hat{y}_i(X_l)$, 设 $\bar{u}_{il} = |\hat{y}_i(X_l)| / \sum_{i=1}^c |\hat{y}_i(X_l)|$, 利用如下公式得到 p_{j1}^i 和 p_{j2}^i 的初始值:

$$p_{j1}^i = \frac{\sum_{l=1}^L \bar{u}_{il} x_{jl}}{\sum_{l=1}^L \bar{u}_{il}},$$

$$p_{j2}^i = \sqrt{\frac{\sum_{l=1}^L \bar{u}_{il} (x_{jl} - p_{j1}^i)^2}{\sum_{l=1}^L \bar{u}_{il}}} \quad (10)$$

(3) 读入训练样本对,计算网络输出,并计算训练误差: $E = \frac{1}{2} \sum_{l=1}^L (y_l - \hat{y}_l)^2$, 若 E 满足精度要求,则跳转到(5),否则继续。

(4) 训练网络。网络中需要调整的网络参数有 $p_{j1}^i, p_{j2}^i, w_{m_i, n_k}$ 和 n_{jk} , 按照 BP 算法调整如下:

$$p_{j1}^i = p_{j1}^i + \eta \delta_i \frac{\partial \mu_i}{\partial p_{j1}^i} + \alpha p_{j1}^{i(\text{old})}$$

$$p_{j2}^i = p_{j2}^i + \eta \delta_i \frac{\partial \mu_i}{\partial p_{j2}^i} + \alpha p_{j2}^{i(\text{old})}$$

$$w_{m_i, n_k} = w_{m_i, n_k} + \eta \delta_i \frac{\partial \mu_i}{\partial w_{m_i, n_k}} + \alpha w_{m_i, n_k}^{(\text{old})}$$

$$n_{jk} = n_{jk} + \eta \delta_i \frac{\partial \mu_i}{\partial n_{jk}} + \alpha n_{jk}^{(\text{old})}$$

其中:

$$p_{j1}^{i(\text{new})} = - \frac{\partial E}{\partial \mu_i} \frac{\partial \mu_i}{\partial p_{j1}^i} + p_{j1}^{i(\text{old})}$$

$$p_{j2}^{i(\text{new})} = - \frac{\partial E}{\partial \mu_i} \frac{\partial \mu_i}{\partial p_{j2}^i} + p_{j2}^{i(\text{old})}$$

$$w_{m_i, n_k}^{(\text{new})} = - \frac{\partial E}{\partial \mu_i} \frac{\partial \mu_i}{\partial w_{m_i, n_k}} + w_{m_i, n_k}^{(\text{old})}$$

$$n_{jk}^{(\text{new})} = - \frac{\partial E}{\partial \mu_i} \frac{\partial \mu_i}{\partial n_{jk}} + n_{jk}^{(\text{old})}$$

式中: η 、 α 分别是学习速率和惯性常数。跳转至(3)。

(5) 获得网络参数 $p_{j1}^i, p_{j2}^i, w_{m_i, n_k}$ 和 n_{jk} , 训练过程结束。

4 算例分析

为了验证方法的可行性和有效性,本文以某市电力系统实际历史负荷为例,用上述 FWN 模型进行短期负荷预测仿真。

选取模型的输入量有 22 个,分别是待测日和待测日前天的最高温度、最低温度、湿度和天气状况;待测日前 1 天的最大、最小及平均负荷;待测日前 1 天及前 2 天分别以预测时段为中心取 5 个负荷值,待测日前一周预测时段的负荷值。输出量有 1 个为待测日某时段的负荷值,本文采取的是逐点预测。利用待测日前六周的历史数据来训练网络。其中学习速率 $\eta = 0.25$, 惯性常数 $\alpha = 0.6$, 学习误差 $E = 0.0005\%$, 尺度 m_i 取 6 个值 ($m_i = -1, 0, 1, 2, 3, 4$), 也即是有 6 条模糊规则。为了比较模型优劣,在选择相同的训练模式、学习速率和惯性常量下,采用人工神经网络模型来进行负荷预测,取预报日为 2001 年 6 月 7 日(正常日),其预测结果见表 1,同时还给出了负荷变化最大、温度和天气状况变化最剧烈几日的预测结果,见表 2。

从预测结果我们可以看出,基于模糊小波网络的负荷预测精度得到显著提高,同时也证明这种方法是完全可行的。从表 1 中还可以发现模糊小波网络的预测相对误差变化很均匀,表明其泛化能力比神经网络大有提高。从表 2 中可以看出模糊小波网络能够更好地拟合负荷与天气因素之间的密切关系,进行更加可靠地预测。

表 1 某市电网负荷预测结果

Tab. 1 Load forecasting results of a certain power network

时间	实际值	FWN 模型		ANN 模型	
		预测值 /MW	相对误差 / %	预测值 /MW	相对误差 / %
1	1077	1095.89	1.7	1040.53	-3.4
2	1032	1022.77	-0.9	1062.22	2.9
3	1005	980.32	-2.5	1051.65	4.6
4	1011	994.52	-1.6	998.66	-1.2
5	1003	1021.95	1.9	996.79	-0.6
6	1035	1058.51	2.3	1002.54	-3.1
7	1152	1126.48	-2.2	1193.36	3.6
8	1189	1198.73	0.8	1221.89	2.8
9	1460	1411.23	-3.3	1394.89	-4.5
10	1523	1501.07	-1.4	1488.21	-2.3
11	1579	1606.82	1.8	1543.77	-2.2
12	1509	1542.59	2.2	1555.19	3.1
13	1424	1389.64	-2.4	1470.92	3.3
14	1455	1477.25	1.5	1464.59	0.7
15	1478	1487.30	0.6	1522.33	3.0
16	1502	1545.45	2.9	1476.39	-1.7
17	1540	1526.19	-0.9	1500.00	-2.6
18	1560	1589.76	1.9	1516.88	-2.8
19	1586	1542.87	-2.7	1526.64	-3.7
20	1570	1538.60	-2.0	1609.72	2.5
21	1524	1546.29	1.5	1557.74	2.2
22	1411	1425.53	1.0	1462.21	3.6
23	1293	1268.43	-1.9	1257.36	-2.8
24	1106	1080.55	-2.3	1143.34	3.4

表 2 预测结果数据

Tab. 2 Forecasting data

预测日期	FWN 模型预测 MAPE/ %	ANN 模型预测 MAPE/ %
7.21	3.673	5.214
8.4	2.855	4.592
8.19	3.387	5.746
6.7	1.841	2.775

$$\text{(其中: MAPE} = \frac{1}{24} \sum_{t=1}^{24} \left| \frac{\hat{y}_t - y_t}{y_t} \right| \times 100 \%)$$

5 结论

由于电力系统日益庞大,各个方面因素的影响使得负荷变化的不确定性增加,这也加大了负荷预测的难度。近年来,许多电力工作者也提出了各种负荷预测模型,其中小波网络便是近年来结合小波变换与人工神经网络思想而形成的一种数学建模方法,研究表明小波网络的预测精度和计算速度比普通神经网络有较大提高,但是小波网络的缺点是一般只适合低维情况,而且为了达到更高的预测精度需要较多的小波函数,为了有效地处理多维问题的

不足,本文提出了一种新颖的基于模糊小波网络的短期负荷预测模型,这种 FWN 模型将小波网络和模糊神经网络有机结合起来,利用一组模糊规则,采用一组小波子网络的结构模型,使得小波子网络的隐层规模大大降低,避免了小波网络的“维数灾”问题,提高了运算效率,通过同时调整小波函数的位移因子和隶属度函数的形状,可以达到全局最优的拟合效果,从而有效地提高了预测精度。通过大量仿真计算表明,该方法是可行且有效的,同时本文为小波网络在电力系统负荷预测中的应用做出了进一步探索研究。

参考文献:

- [1] 牛东晓,邢棉,等(NIU Dong-xiao,XING Mian,et al). 短期电力负荷预测的小波神经元网络模型的研究(Wavelet Neural Network Model for Short-term Load Forecasting)[J]. 电网技术(Power System Technology),1999,23(4):21-24.
- [2] Mukerjee S,Nayar S K. Automatic Generation of RBF Networks Using Wavelet[J]. Pattern Recognition,1996,29(8):1369-1383.
- [3] 徐长发,李宽国(XU Chang-fa, Li Kuang-guo). 实用小波方法(Practical Wavelet Method)[M]. 武汉:华中科技大学出版社(Wuhan:Huazhong University of Science and Technology Press),2001.
- [4] 邵能灵,候志俭,李涛,等(TAI Neng-ling,HOU Zhi-jian,LI Tao,et al). 基于小波分析的电力系统短期负荷预测方法(New Principle Based on Wavelet Transform for Power System Short-term Load Forecast)[J]. 中国电机工程学报(Proceedings of the CSEE),2003,23(1):45-50.
- [5] Papadakis S E,Theocharis J B,et al. A Novel Approach to Short-term Load Forecasting Using Fuzzy Neural Networks[J]. IEEE Transactions on Power System,1998,13(2):480-492.

收稿日期:2003-06-23; 修回日期:2003-08-10

作者简介:

汪新秀(1978-),女,硕士研究生,研究方向为电力系统规划方法及应用;

吴耀武(1963-),男,副教授,从事电力系统及其自动化方面的科研和教学工作,研究方向为电力系统运行分析与规划;

熊信银(1945-),男,教授,从事电力系统及其自动化方面的科研和教学工作,研究方向为电力系统运行分析与规划。

SVM 与 Fourier 算法在电网短期负荷预测中的应用

杨镜非, 谢宏, 程浩忠

(上海交通大学电气工程系, 上海 200030)

摘要: 将 Fourier(傅立叶)算法与 SVM(支持向量机)共同引入电网短期负荷预测。对于波动性较大的负荷, Fourier 算法用于滤除高次谐波分量。SVM 用于对滤除了高次分量的数据进行统计学习,它首先筛选与预测点相关的历史数据构成训练样本,再将预测的平滑性和误差损失函数相结合构成问题的目标函数进行求解。编制了相应的软件,对某实际电网进行了短期负荷预测,取得了理想的结果。

关键词: 负荷预测; 支持向量机; 傅立叶算法; 损失函数; 核函数

中图分类号: TM715 **文献标识码:** A **文章编号:** 1003-4897(2004)04-0017-03

0 引言

电力系统负荷预测是电网能量管理系统的重要内容,通过精确的负荷预测,可以经济合理地安排机组启停,减少旋转备用容量,合理安排检修计划,降低发电成本,提高经济效益。常用的方法有非线性回归、神经网络法、时间序列法、模糊理论等。非线性回归和时间序列法在电网情况正常、生产和气象变化不大的时候预测效果良好,但不能考虑一些影响负荷的要素,如休息日、气象等,当这些因素发生突变时预测精度受到影响。神经网络和模糊理论考虑到了影响负荷的一些不确定因素,但没有彻底解决网络结构设计的难题,且需要较长的训练时间。

SVM(支持向量机)是由 Vapnik^[1]最早提出的一种统计学习方法,近年来已经被成功地应用于语音识别、文字识别、时序数列预测等领域。研究显示,该统计学习方法具有学习速度快、全局最优和推广能力强的优点,其学习结果经常明显好于其它的模式识别和回归预测方法。本文将 SVM 理论应用于电力系统短期负荷预测,既考虑了影响负荷的诸因素,又建立了完善的数学模型。

SVM 算法对于预测负荷曲线较平滑的系统,能够取得较理想的效果。但是,对于惯性较小、随机波动性较强的中小型电网,其效果相对较差。改进的方法是,先采用 Fourier 算法将历史负荷曲线分解为平滑曲线和随机波动曲线两部分,只采用平滑部分作为 SVM 的历史训练数据,能够取得更好的效果。

1 SVM 线性回归模型

假设有一组训练数据,其中第 i 个数据包含变量 $x_i \in R^n$ 和与之相对应的变量 $y_i \in R$, SVM 定义了一种机器(machine),用于确定 x 到 y 的映射关系 $X \rightarrow f(X)$, f 为可调参数,通过对已知数据的学习来确定它。在线性回归中,定义映射函数 $f(x) = \langle w, x \rangle + b$, $w \in R^n, y \in R$,并要求:1) 找到最小的 ϵ 以保证曲线的平滑性,一种常用的方法是使得 ϵ 的欧氏二范数最小;2) 映射的误差在允许的范围之内。可以写成下列数学模型:

$$\begin{aligned} & \text{minimize } \frac{1}{2} \|w\|^2 & (1) \\ & \text{subject to } \begin{cases} y_i - \langle w, x_i \rangle - b \leq \epsilon \\ \langle w, x_i \rangle + b - y_i \leq \epsilon \end{cases} & (2) \end{aligned}$$

A method of power system short-term load forecasting based on fuzzy wavelet neural networks

WANG Xir xiu, WU Yao-wu, XIONG Xir yin, HUANG A-qiang
(Huazhong University of Science and Technology, Wuhan 430074, China)

Abstract: A novel short-term load forecasting model based on fuzzy wavelet neural networks(FWN) is presented in this paper. Because FWN combines the time-frequency localization ability of wavelet, fuzzy inferring and the education character of ANN together, its ability to reach the global best results is greatly improved. The FWN includes a set of fuzzy rules and several sub-WNNs. Every sub-WNN, corresponding to a certain fuzzy rule, consists of wavelets with a specified dilation. By adjusting the translation parameters of the wavelets and the shape of membership functions, the accuracy and generalization capability of FWN can be remarkably improved. The calculation result shows that the presented model is effective.

Key words: load forecasting; wavelet; fuzzy wavelet neural networks(FWN)