文章编号:1671-4598(2020)01-0156-04　DOI:10.16526/j.cnki.11-4762/tp.2020.01.033　中图分类号:TM92　文献标识码:A

基于自适应卡尔曼滤波在气象影响下负荷预测

罗　权
(华南理工大学 电力学院, 广州　510000)

摘要: 如今电网系统中所构成电力负荷的电器越来越多, 其中像空调等受气象影响的负荷所占比例持续升高, 那么气象因素(温度、湿度、降雨量等)对电网的影响自然越来越突出, 因此短期负荷预测将气象因素考虑进去, 能够大大提升预测精度; 根据某地区六年的电力负荷数据, 构建卡尔曼滤波模型, 可以给出高效准确的预测结果; 然后将气象因素考虑到自适应卡尔曼滤波模型, 通过不断对状态估计进行修正, 得到计及气象因素影响的负荷预测结果精度更高; 通过 MATLAB 仿真, 说明这种算法比较传统的卡尔曼滤波具有更高的预测精度, 而且这种改进后的算法对实现短期负荷预测提供了一条新的途径。

关键词: 短期负荷预测; 气象因素; 卡尔曼滤波; MATLAB

Short-term Load Forecasting Under Meteorological Influence Based on Adaptive Kalman Filter

Luo Quan
(School of Electric Power, South China University of Technology, Guangzhou　510000, China)

Abstract: Nowadays, there are more and more electric appliances constituting power load in the power grid system. Among them, the proportion of load affected by weather, such as air conditioning, keeps increasing. Therefore, the influence of meteorological factors (temperature, humidity, rainfall, etc.) on the power grid is more and more prominent. Considering meteorological factors becomes one of the main means for the dispatching center to further improve the load forecasting accuracy. According to the load data of a certain area for six years, the Kalman filter model can give the accurate and efficient prediction results. Then, the meteorological factors are taken into account in the adaptive Kalman filter model, and the load prediction results with meteorological factors taken into account are more accurate through constant modification of the state estimation. Through the Matlab simulation, it shows that the algorithm is more accurate than traditional Kalman filter, and the modified algorithm provides a new way for short-term load forecasting.

Keywords: short-term load forecasting; meteorological factors; Kalman filter; Matlab

0　引言

在电网的调度运行中, 短期负荷预测起着重要的指导作用, 精准的负荷预测不仅仅可以提高电力系统运行的可靠性和稳定性, 而且可以大大降低电网运行成本。直接关系到电网运行经济效应的负荷预测精度, 同时也与电网科学化管理和自动化程度密切相关, 并且现代电网建设需要大规模并网, 高效精确的负荷预测就显得格外重要了, 这也是大量研究人员一直以来所追求的。

对负荷预测的研究历程中, 人们结合数据分析和概率论发展了许多方法, 有传统的回归分析法和最小二乘法, 也有时间序列法和小波分析法, 以及几经波折的神经网络。它们均有各自优缺点, 例如回归分析法计算原理简单、外推性能好、运算速度快, 时间序列法的预测值能体现出负荷变化的连续性, 且该算法的运算速度也快, 但是这两种方法在进行负荷预测时都没有考虑到负荷影响因素, 负荷预测误差较大。其他负荷预测方法就不再一一赘述。而本文所采用的卡尔曼滤波算法不仅能很好的解决信号中的噪声问题, 还具有较为良好的预测性能。

虽然斯坦利·施密特(Stanley Schmidt)首次实现了卡尔曼滤波器, 但卡尔曼(R. E. Kalman)在 1960 年其论文《线性滤波和预测理论的新成果》中首次提出一种新的线性滤波和预测理由论, 即卡尔曼滤波。它是威纳滤波的发展, 克服了威纳滤波的局限性, 能很好的解决各种最优滤波和最优控制问题, 在工程上得到了广泛的应用, 尤其在控制、通讯等现代工程方面。卡尔曼滤波原理是通过线性空间概念来描述所研究的数学公式, 用系统的状态方程和观测方程构成新型线性随机系统的状态空间模型来描述该滤波器, 运用状态方程的递推性推出最优解, 此解满足线性无偏最小均方差估计准则。卡尔曼滤波算法复杂度低, 计算机编程较为容易, 这也是其运用广泛的原因之一。

本文根据某地区六年的电力负荷数据, 构建传统的卡尔曼滤波模型的基础上, 再增加五个气象因素, 从而相应的改进算法, 构建的自适应卡尔曼滤波模型, 大大的提高了预测精度。

1　基本卡尔曼滤波理论

卡尔曼滤波算法作为一种递推滤波的方法, 它的基本

收稿日期:2019-06-06;　**修回日期:**2019-07-10。
作者简介:罗　权(1996-),男,江西赣州人,硕士在读,主要从事电气故障监测方向的研究。

动态系统可以用一个马尔科夫链表示，取一个向量表示系统状态，向量元素为实数。这样一个线性算子伴随时间作用在当前状态下会产生一个新的状态，同时也会混入噪声，再者一些已知的控制信息也被引入进去。此时就可以用另外一个线性算子表示受噪声干扰的因素，来观测这些隐含状态的输出。

将输入噪声 W_k 和 V_k 量测噪声考虑进来时，系统状态方程与测量方程可以描述为：

$$\hat{x}_k = F\hat{x}_{k-1} + B\mu_{k-1} + QWk-1 \tag{1}$$

$$z_k = H\hat{x}_k + RV_k \tag{2}$$

式中，$\hat{x}$ 为最优估计（对第 k 步状态得出的最优估计值而言）；μ_{k-1}为 n 维输入（或控制向量）。

卡尔曼滤波器的模型可以用以下原理图（图 1）表示。其中圆圈表示向量，方块表示矩阵，星号表示高斯噪声。

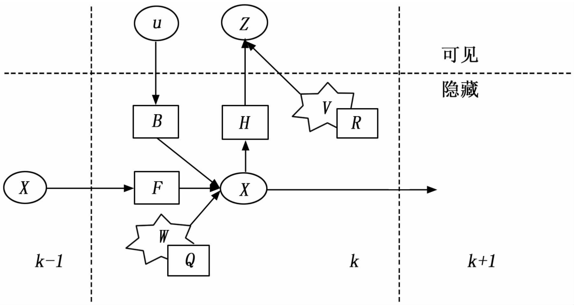

图 1　卡尔曼滤波原理图

投影法推导的卡尔曼滤波器递推公式和预测方程为：

预测状态方程：

$$\hat{x}_{k|k-1} = \boldsymbol{F}_{k,k-1}\hat{x}_{k-1|k-1} \tag{3}$$

误差协方差矩阵预测：

$$\boldsymbol{P}_{k|k-1} = \boldsymbol{F}_{k,k-1}\boldsymbol{P}_{k-1}\boldsymbol{F}^T_{k,k-1} + \boldsymbol{Q}_{k-1} \tag{4}$$

更新状态估计：

$$\hat{x}_{k|k} = \hat{x}_{k|k-1} + \boldsymbol{K}_k[z_k - \boldsymbol{H}_k\hat{x}_{k|k-1}] \tag{5}$$

更新误差协方差估计：

$$\boldsymbol{P}_{k|k} = (\boldsymbol{I} - \boldsymbol{K}_k\boldsymbol{H}_k)\boldsymbol{P}_{k|k-1} \tag{6}$$

最优卡尔曼增益：

$$\boldsymbol{K}_k = \boldsymbol{P}_{k|k-1}\boldsymbol{H}^T_k(\boldsymbol{H}_k\boldsymbol{P}_{k|k-1}\boldsymbol{H}^T_k + \boldsymbol{R}_k)^{-1} \tag{7}$$

假设状态方程的输入噪声和测量噪声是互不干扰的，均值为 0 的独立白噪声，其具有如下的统计特性：

$$\boldsymbol{E}[\omega_k] = \boldsymbol{E}[\upsilon_k] = \boldsymbol{E}[\omega_k\upsilon^T_j] = 0 \tag{8}$$

$$\boldsymbol{E}[\omega_k\omega^T_j] = \boldsymbol{Q}_k, \boldsymbol{E}[\upsilon_k\upsilon^T_j] = \boldsymbol{R}_k \tag{9}$$

一般情况下，滤波初始值 $\hat{x}_0 = 0, \boldsymbol{P}_0 = c\boldsymbol{I}$,其中 0 和 $\boldsymbol{I}$ 均是相应维数的零矩阵和单位矩阵,$\boldsymbol{c}$ 为足够大的常数，是为了能够包含初始估计误差的最大变化范围。

如果这基本的卡尔曼滤波直接运用到负荷预测，是要将电力系统考虑成线性系统，但如果发生异常情况，例如不良数据的存在，网络拓扑结构的错误，负荷发电机输出功率的突变，那么滤波的结果就会受很大的影响，致使状态估计的准确度下降。这也是接下来要讨论的，对卡尔曼滤波进行改进，以应对以上问题，以达到负荷预测不仅有很高的精准度，而且有很好的抗扰动性。

1.1　自适应卡尔曼滤波

自适应滤波简而言之，就是滤波系统的参数受输出信号与期望信号之差（即误差信号）控制，根据误差信号自动调整，使之适应下一时刻的输入，以提高滤波精度，最终达到良好滤波效果。

当模型参数 $F_{k,k-1}$ 、B_k 、H_k 以及 Q_k 、R_k 随着时间变化时，则（7）为参数时变系统，否则为定常数系统（即定常噪声协方差）。根据状态方程自身的特点，本文不采用定常数系统，所用的模型为参数时变系统，应采用自适应卡尔曼滤波系统。而在实际负荷预测中很难准确获得 Q_k、R_k 的值，为此引入时变噪声统计估值器。

用估计值 $\hat{Q}_k$、$\hat{R}_k$ 分别代替式（4）、（7）中的 Q_k、R_k，然后引入下面几个方程：

$$G_k = [B^T_kB_k]^{-1}B^T_k \tag{10}$$

$$Q_{k+1} = (1-z_k)\,Q_k + z_kG_kK_{k+1}\varepsilon_{k+1}\varepsilon_{k+1}{}^TK_{k+1}{}^T + P_{k+1|k+1} - F_{k+1,k}P_{k|k}F_{k+1}{}^TG_k{}^T \tag{11}$$

$$\hat{R}_{k+1} = (1-z_k)\hat{R}_k + z_k(\varepsilon_{k+1}\varepsilon^T_{k+1} - C_{k+1}P_{k+1|k}C^T_{k+1}) \tag{12}$$

式中，z_k、$1-z_k$ 用于指数加权。所谓指数加权是指对旧数据和新数据给予不同的权系数，使得新数据在估计中发挥主要作用，而使旧数据逐渐被遗弃。其权系数按负指数函数的规律赋予。

由于上式为了满足无偏估计的要求而采用相减算法，同时也引起了滤波发散，所以采取下列偏估计式：

$$\hat{Q}_{k+1} = (1-z_k)\hat{Q}_k + z_k(G_kK_{k+1}\varepsilon_{k+1}\varepsilon^T_{k+1}K^T_{k+1} + P_{k+1|k+1}G^T_k) \tag{13}$$

$$\hat{R}_{k+1} = (1-z_k)\hat{R}_k + z_k\varepsilon_{k+1}\varepsilon^T_{k+1} \tag{14}$$

1.2　两端自适应卡尔曼滤波

针对以上两个线性时变状态方程进行卡尔曼滤波，运用两端自适应滤波的方法，流程图 2 如下所示。

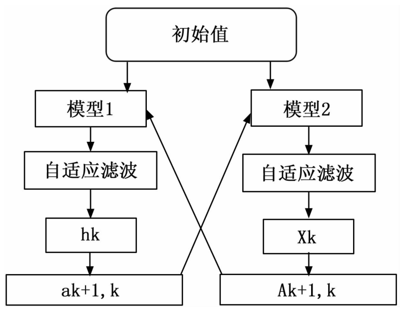

图 2　自适应滤波流程图

不难看出，两端自适应卡尔曼滤波，可以选择从两模型之一开始递推，最终效果是一致的，具体步骤可以如下(从模型 2 开始)：

1）将初始条件代入以系数序列为状态变量的模型 2 中，通过运用式（3）～（7）以及式（10）、(13)、(14）进行自适应卡尔曼滤波，可求出状态变量 x_k

2）再用状态变量 x_k 求出模型 1 所需的状态转移矩阵 $\boldsymbol{A}_k+1, k$，重复 1）的递推，可求出状态变量 h_k。

3）重复步骤 2)，将模型 2 所需的状态转移矩阵 $\boldsymbol{A}_k+1, k$ 迭代进去。

4）通过以上自适应估计交替计算，最后的预测方程为：

$$\hat{h}_{k+1|k}=\hat{h}_{k|k}$$

再由 $\hat{h}_{k+1|k}$ 得到对应的 $\hat{F}$，则可得到状态估计值：

$$\hat{x}_{k+1|k}=\hat{F}\hat{x}_{k|k}$$

以及 $\hat{y}_{k+1|k}=C\hat{x}_{k+1|k}$

2 未计气象因素自适应卡尔曼滤波负荷预测

系统方程的建立：

$$f_h(k)=f_h(k-1)+w(k-1) \tag{15}$$

观测方程的建立：

$$y(t)=[1\quad 0\quad 0]\times[x(t)\times x(t-1)T(t)]'+u \tag{16}$$

根据本文短期负荷预测系统，求初始参数：Rx 为四参数初始变量，分别为 $t-1$ 时刻负荷，$t-2$ 时刻负荷，日常系数 T，和常数 1。

$Rx=$［$t-1$ 负荷 $t-2$ 负荷 T 常数 1］$n*4$

Ry 为初始数据向量，表示的是 t 时刻的列向量。

$Ry=$［t 时刻的负荷］$n*1$

通过转移矩阵 F 和观测 H，获得以下初始变量：

$R_{ww}=$［（$b1$（1）$-b2$（1））^2/$round$（N/2）0 0；0 0 0；0 0 var（T）］；

$R_{vv}=var$（r）/（$N-3-1$）；

以下是根据某地区从 2009 年 1 月 1 日至 2015 年 1 月 10 日的电力负荷数据，运用自适应卡尔曼滤波负荷预测模型对对该地区 2015 年 1 月 11 日至 17 日共 7 天的电力负荷进行预测。通过（5）～（7）对应的式子，求出卡尔曼增益以及协差的值，通过 MATLAB 程序可获得相应数据：

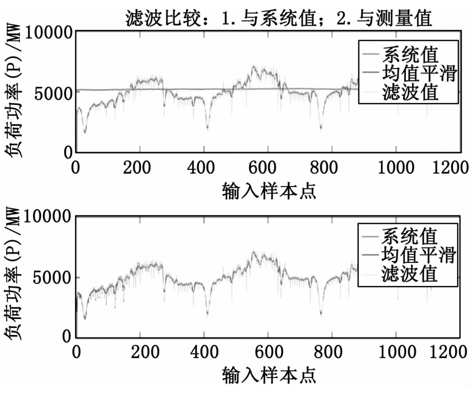

图 3 卡尔曼滤波比较

上图可观察到经过卡尔曼滤波后，历史数据在训练后所呈现一定的周期性趋势及通过均值平滑过程所产生的较为贴近现实数据的平滑曲线。

通过自适应过程后，在利用测量数据进行滤波的同时，不断地由滤波本身去判断系统的动态是否有变化，对模型参数和噪声统计特性进行估计和修正，以改进滤波设计、缩小滤波的实际误差。此种滤波方法将系统辨识与滤波估计有机地结合为一体。这样可以‘*’所表示的预测值于线的测量值高精确度重合，代表模型高效准确的预测结果。

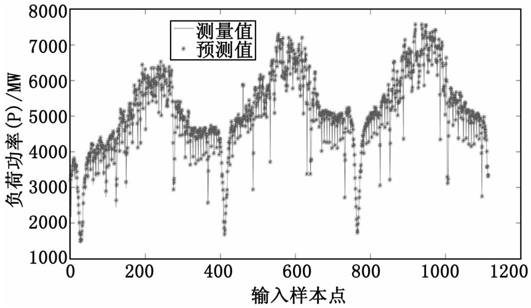

图 4 预测值与测量值的比较

图 4 能较为直观地看出到此模型预测结果与测量值的相对性，为了更好的体现出该模型的适应能力，可以做出如下精密的误差分析。如图 5 所示。

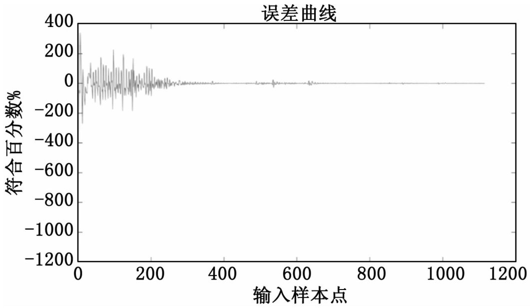

图 5 预测值与测量值的误差线

通过此误差曲线，可以分析得出，当此模型在不停地训练运算过程中，误差值一直在减小，直至最后趋于 0 这样的理想状态。虽然过程中仍会有少数噪音干扰，但是对于在大量数据下训练后的出的预测结果造成的影响是微乎其微，可以忽略的。

3 计及气象因素自适应卡尔曼滤波负荷预测

在模型 2 的基础上，将所采集的气象因素（日最高温度、日最低温度、日平均温度、日相对湿度以及日降雨量）考虑进去，我们可以得出如下方程：

$$\boldsymbol{X}_n=(x_{n-p=+1}\times x_{n-p+2}\cdots x_n) \tag{17}$$

$$\boldsymbol{H}=[0\quad 0\quad \cdots\quad 0\quad 1] \tag{18}$$

$$\boldsymbol{F}=\begin{pmatrix}0 & \cdots & 1 & 0 & 0\\ 0 & \cdots & 0 & 1 & 0\\ 0 & \cdots & 0 & 0 & 1\\ a_p & \cdots & a_3 & a_2 & a_1\end{pmatrix} \tag{19}$$

由于语音信号短时平稳，因此在进行卡尔曼滤波之前对信号进行分帧加窗操作，在滤波之后对处理得到的信号进行合帧，这里选取帧长为 256，而帧重叠个数为 128。

图 6 为原数据与加噪声后的数据（既计及气象因素数据）以及历史信号与经卡尔曼滤波处理后的信号。

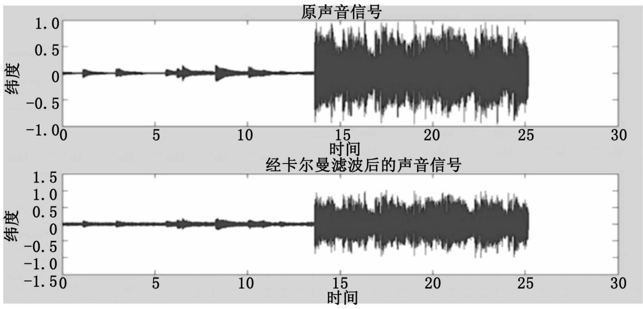

图 6　经卡尔曼滤波后信号的比

由此，我们可以明显地看出，通过自适应卡尔曼滤波将 5 个气象因素与全年负荷关联对应，并对数据进行筛选剔除，得到数据后再将 5 要素通过卡尔曼滤波预测模型构成相当于不同权重情况下各个因素对负荷功率的影响，得出的预测数据与历史数据更为精确。

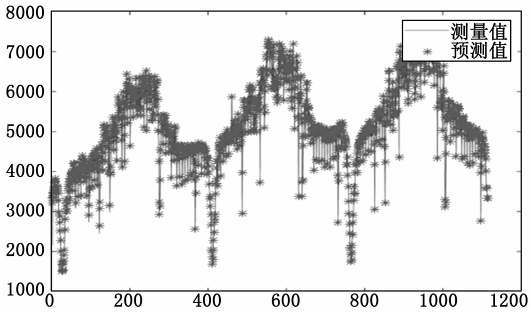

图 7　经卡尔曼滤波后输出的预测值与测量值

根据数据预测得到预测值于测量值对比的图形，我们能比较清晰地看出预测值在测量值的范围内波动，但并不能直观体现计及气象因素影响下的短期负荷预测与未计气象因素的差别，于是我们将在未计及气象因素情况下所得到的误差图形与此时计及气象因素所得到的误差图形进行对比，该步骤可用 Matlab 程序得到图 8。

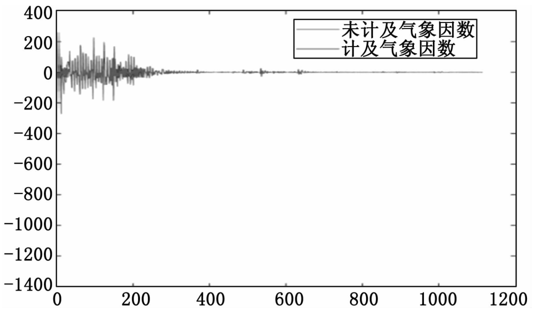

图 8　计及气象因素误差比较

从图 8 已经可以明显观察到计及气象因素所照成的误差要比未计及气象因素所照成的误差更小，再截取一部分预测值与真实值的相对误差进行数值上的直观对比（见表 1），更能印证计及气象因素对提升短期负荷预测的精准性有显著的效果。

不难从表 1 中看出，在一开始的预测中未计及和计及气象因素的相对误差都非常大，处于振荡阶段，但卡尔曼滤波器会在递推过程中不断用新的信息对状态估计进行修正，所以卡尔曼滤波是渐进稳定的，当时间序列足够长时，初始状态的状态值、协方差阵对估计的影响都将衰减为零。所以卡尔曼滤波模型能够不断更新状态信息，获得比较准确的估计值。相比较而言，我们可以认为计及气象因素影响的负荷预测结果精度更高更准确。

表 1　相对误差分析

日期	未计及气象因素	计及气象因素
20090101	0	0
20090102	−1120.891799	−971.5811534
20090103	−181.713636	−204.3674401
20090104	−46.24496302	−136.0191381
20090105	−68.08653802	−28.74344478
20090106	364.3704806	−3.479402409
20090107	289.5198699	−8.389429813
20090108	230.7823653	−29.87607367
20090109	121.6382771	−39.33195683
	...	
20101215	−0.597014724	1.220253496
20101216	−1.80493392	−2.08342511
20101217	−3.751600313	0.469395645
20101218	6.593286965	0.341138621
20101219	4.914524145	−0.680724636
20101220	−8.478695456	−1.417485992
20101221	2.047385118	1.729242866
20101222	3.917342526	1.393563522
20101223	−3.705200003	−1.363898406

4　结语

本文通过建立时变动态模型，再运用两端自适应卡尔曼滤波的方法进行了短期负荷预测，充分利用自适应方法的跟踪性能优良的特点，使状态参数能敏感地直接反映各种影响因素造成的变化。通过实际数据和算法证实了自适应卡尔曼滤波模型的可行性，但不仅局限于此，本文在原有的基础上，引入了气象因素作为修正系数，得出的负荷预测结果更为精准和收敛更为迅速，由此印证了气象因素（温度、湿度、降雨量等）对现代电力系统负荷的影响愈显突出，考虑气象因素成为调度中心进一步改进负荷预测精度的主要手段之一。对此提出假设，是否能将影响地域负荷的因素，加入到自适应卡尔曼滤波算法当中，提高当地短期负荷预测的准确性，例如某地工业比较发达，可以将该地的工厂上下班时间作为一个影响因子。乃至随着技术的发展，可有设备能分析记录用户各种用电参数，极大提高短期负荷的准确性。

（下转第 165 页）