

Пояснение Основ фильтра Калмана С помощью Простого и интуитивно понятного Выведения

Эта статья предоставляет простой и интуитивный вывод фильтра Калмана, с целью обучения этому полезному инструменту для студентов. Он не требует сильной математической базы. Самый сложный уровень математики, необходимый для понимания этого вывода это умножение двух Гауссовых функций и перевод результата в компактную форму.

Возраст фильтра Калмана составляет более 50 лет, но он до сих пор один из наиболее важных и распространенных алгоритмов синтеза данных, используемых сегодня. Названный в честь Рудольфа Э. Калмана, большой успех фильтра Калмана обусловлен его небольшими вычислительными требованиями, прекрасными рекурсивными свойствами и его статусом оптимальной оценки для одномерных линейных систем с Гауссовой статистикой ошибок [1]. Типичное использование фильтра Калмана включает сглаживание зашумлённых данных и предоставление оценок интересующих параметров. Применение включает в себя приемники глобальной системы позиционирования, фазированные петли в радиооборудовании, сглаживание выходных данных от трекпадов ноутбуков и многое другое.

С теоретической точки зрения, фильтр Калмана представляет собой алгоритм, позволяющий

точно умозаключить в линейной динамической системе, которая является Байесовской моделью скрытую Марковскую модель, но где пространство состояний скрытых переменных непрерывно и где все скрытые и наблюдаемые переменные имеют Гауссовское распределение (часто многомерное Гауссовское распределение). Цель этой статьи состоит в том, чтобы позволить людям, которые находят это описание путающим или страшным, понять систему фильтра Калмана с помощью простого и интуитивного вывода.

АКТУАЛЬНОСТЬ

Фильтр Калмана [2] (и его варианты, такие как расширенный фильтр Калмана [3] и упрощённый фильтр Калмана [4]) является одним из самых знаменитых и популярных алгоритмов слияния данных в области обработки информации. Самое известное раннее использование фильтра Калмана было на навигационном компьютере Apollo, который взял Нил Армстронг на Луну, и (что наиболее важно) вернул его. Сегодня фильтры Калмана работают в каждом спутниковом навигационном устройстве, каждом смартфоне и многих компьютерных играх.

ФИЛЬТР КАЛМАНА СОЗДАН БОЛЕЕ 50 ЛЕТ НАЗАД. НО ВСЁ ЕЩЁ ЯВЛЯЕТСЯ ОДНИМ ИЗ САМЫХ ВАЖНЫХ И РАСПРОСТРАНЁННЫХ АЛГОРИТМОВ ФИЛЬТРАЦИИ, ИСПОЛЪЗУЕМЫХ СЕГОДНЯ.

Фильтр Калмана обычно выводится с использованием векторной алгебры в качестве минимальной среднеквадратической оценки [5], это подход, подходящий для студентов, уверенных в математике, но не тот, который

легко понять студентам, дисциплины которых не требуют сильной математической базы. Фильтр Калмана выводится здесь из основных принципов, рассматривая простой физический пример, использующий ключевое свойство Гауссовского распределения, а именно свойство того, что произведение двух Гауссовых распределений является новым Гауссовским распределением.

ПРЕДПОСЫЛКИ

Эта статья не предназначена для тщательного изучения студентами фильтра Калмана в интересах краткости, но вместо этого направлена на то, чтобы предоставить преподавателям простой метод обучения концепций фильтра Калмана студентам, которые не сильны в математике. Ожидается, что читатель будет знаком с векторной нотацией и терминологией, связанной с фильтрацией Калмана, такой как вектор состояния и ковариационная матрица. Эта статья предназначена для тех, кто хочет понять фильтр Калмана другим простым и интуитивным образом или для тех, кто уже имеет некоторый опыт работы с фильтром Калмана, но может не полностью понять его основы. Эта статья не предназначена для полного и автономного образовательного инструмента для всех новичков, поскольку для этого потребуются больше чем несколько страниц.

ПОСТАНОВКА ЗАДАЧИ

Модель фильтра Калмана предполагает, что состояние системы за время t эволюционировало из предыдущего состояния в момент времени $t-1$ в соответствии с уравнением

$$\mathbf{x}_t = \mathbf{F}_t \mathbf{x}_{t-1} + \mathbf{B}_t \mathbf{u}_t + \mathbf{w}_t \quad (1)$$

где

■ \mathbf{x}_t - вектор состояния, содержащий интересующие переменные системы (например, положение, скорость, ускорение) в момент времени t

■ \mathbf{u}_t - вектор, содержащий любые управляющие входы (угол поворота,

регулировка дроссельной заслонки, тормозное усилие)

■ F_t - матрица перехода состояний, которая изменяет переменные состояния системы в момент времени $t-1$ в состоянии системы в момент времени t (например, положение и скорость в момент времени $t-1$ влияют на положение в момент времени t)

■ V_t - матрица управляющего входа, которая применяет эффект каждого управляющего входного параметра в векторе u_t на векторе состояния (например, применяет влияние настройки дроссельной заслонки на скорость и положение системы)

■ w_t - вектор, содержащий условия шума процесса для каждого параметра в векторе состояния. Предполагается, что шум процесса берется из нулевого среднего многомерного нормального распределения с ковариацией, заданной ковариационной матрицей Q_t . Измерения системы также могут выполняться в соответствии с моделью

$$z_t = H_t x_t + v_t, \quad (2)$$

где

■ z_t - вектор измерений

■ H_t - матрица преобразования, которая отображает параметры вектора состояния в область измерения

■ v_t - вектор, содержащий условия измерения шума для каждого наблюдения в векторе измерения. Как и шум процесса, шум измерения считается нулевым средним Гауссовским белым шумом с ковариацией R_t .

В следующем примере мы рассмотрим простую одномерную проблему отслеживания, в частности, поезд, движущийся вдоль железнодорожной линии (см. Рис. 1). Поэтому мы можем рассмотреть некоторые примеры векторов и матриц в этой задаче. Вектор состояния x_t содержит положение и скорость поезда

$$x_t = \begin{bmatrix} x_t \\ \dot{x}_t \end{bmatrix}.$$

Водитель поезда может использовать тормозной или ускоряющий вход системы, который мы рассмотрим здесь как функцию приложенной силы f_t и массы поезда m . Такая управляющая информация сохраняется в векторе управления u_t

$$u_t = \frac{f_t}{m}.$$

Соотношение между силой, приложенной через тормоз или дроссель в течение периода времени Δt (время, прошедшее между временными интервалами $t-1$ и t) и положение и скорость поезда, задается следующими уравнениями:

$$x_t = x_{t-1} + (\dot{x}_{t-1} \times \Delta t) + \frac{f_t (\Delta t)^2}{2m}$$

$$\dot{x}_t = \dot{x}_{t-1} + \frac{f_t \Delta t}{m}.$$

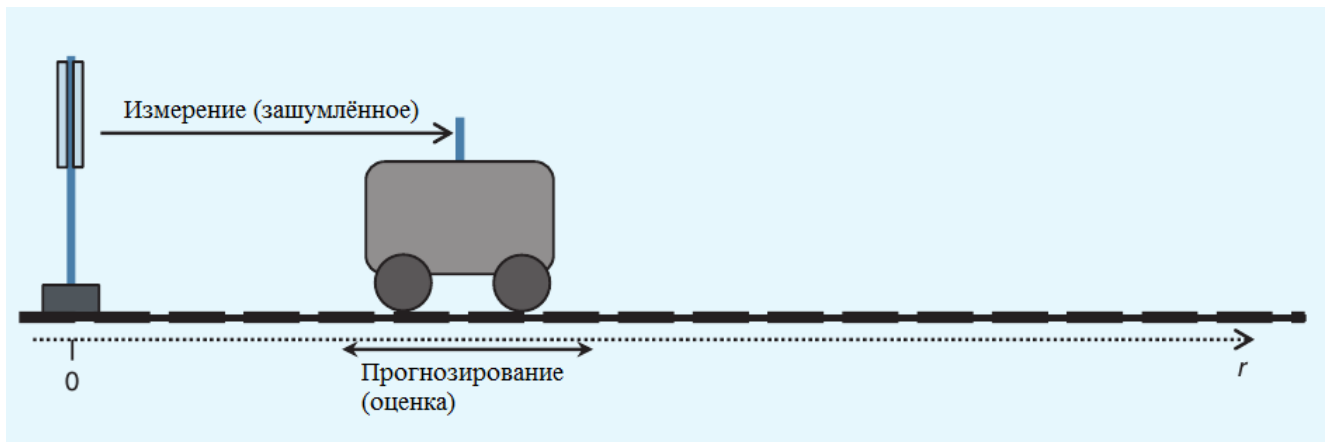
Эти линейные уравнения могут быть записаны в матричной форме как

$$\begin{bmatrix} x_t \\ \dot{x}_t \end{bmatrix} = \begin{bmatrix} 1 & \Delta t \\ 0 & 1 \end{bmatrix} \begin{bmatrix} x_{t-1} \\ \dot{x}_{t-1} \end{bmatrix} + \begin{bmatrix} \frac{(\Delta t)^2}{2} \\ \Delta t \end{bmatrix} \frac{f_t}{m}.$$

Итак, по сравнению с (1), для этого примера мы можем видеть, что

$$F_t = \begin{bmatrix} 1 & \Delta t \\ 0 & 1 \end{bmatrix} \quad V_t = \begin{bmatrix} \frac{(\Delta t)^2}{2} \\ \Delta t \end{bmatrix}.$$

Нельзя непосредственно наблюдать истинное состояние системы x_t , а фильтр Калмана предоставляет алгоритм для определения оценки \hat{x}_t путем комбинирования моделей системы и зашумлённых измерений некоторых параметров или линейных функций параметров. Поэтому оценки интересующих параметров в векторе состояния теперь предоставляются функциями плотности вероятности (ФПВ), а не дискретными значениями. Фильтр Калмана основан на Гауссовских ФПВ-файлах, как станет ясно после вывода, описанного ниже в разделе «Решения». Чтобы полностью описать Гауссовы функции, нам нужно знать их дисперсии и ковариации, и они хранятся в ковариационной матрице P_t . Слагаемые вдоль главной диагонали P_t представляют собой дисперсии, связанные с соответствующими членами вектора состояния. Недиагональные члены P_t обеспечивают ковариации между членами в векторе состояния. В случае хорошо смоделированной одномерной линейной системы с ошибками измерения, полученными из нулевого среднего распределения Гаусса, считается, что фильтр Калмана даёт оптимальную оценку [1]. В оставшейся части этой статьи мы выведем уравнения фильтра



[рис1] На этом рисунке показана рассматриваемая одномерная система.



[Рис.2] Начальное знание системы в момент времени $t = 0$. Красное Гауссовское распределение представляет собой ФПВ, что обеспечивает первоначальную уверенность в оценке положения поезда. Стрелка, указывающая вправо, представляет собой известную начальную скорость поезда.

Калмана, которые позволят нам рекурсивно вычислять x_t путем объединения предшествующих значений, прогнозов из системных моделей и зашумлённых измерений.

Алгоритм фильтра Калмана включает в себя два этапа: прогнозирование и обновление измерений. Стандартными уравнениями фильтра Калмана для стадии прогнозирования являются

$$\hat{x}_{t|t-1} = F_t \hat{x}_{t-1|t-1} + B_t u_t \quad (3)$$

$$P_{t|t-1} = F_t P_{t-1|t-1} F_t^T + Q_t \quad (4)$$

где Q_t - матрица ковариации шума процесса, связанная с шумными управляющими входами. Уравнение (3) было получено явно и приведено выше. Мы можем получить (4) следующим образом. Дисперсия, связанная с предсказанием x_t ; $t-1$ неизвестного истинного значения x_t , задается формулой

$$P_{t|t-1} = E[(x_t - \hat{x}_{t|t-1})(x_t - \hat{x}_{t|t-1})^T],$$

и принимая разницу между (3) и (1), дает

$$\begin{aligned} x_t - \hat{x}_{t|t-1} &= F(x_{t-1} - \hat{x}_{t-1|t-1}) + w_t \\ &= P_{t|t-1} = E[(F(x_{t-1} - \hat{x}_{t-1|t-1}) \\ &\quad + w_t) \times (F(x_{t-1} - \hat{x}_{t-1|t-1}) \\ &\quad + w_t)^T] \\ &= FE[(x_{t-1} - \hat{x}_{t-1|t-1}) \\ &\quad \times (x_{t-1} - \hat{x}_{t-1|t-1})^T] \\ &\quad \times F^T + FE[(x_{t-1} \\ &\quad - \hat{x}_{t-1|t-1})w_t^T] \\ &\quad + E[w_t x_{t-1} \\ &\quad - \hat{x}_{t-1|t-1})^T] F^T \\ &\quad + E[w_t w_t^T]. \end{aligned}$$

Отмечая, что ошибки оценки состояния и шум процесса не коррелируют

$$\begin{aligned} E[(x_{t-1} - \hat{x}_{t-1|t-1})w_t^T] \\ &= E[w_t(x_{t-1} - \hat{x}_{t-1|t-1})^T] = 0 \\ &\Rightarrow P_{t|t-1} = FE[(x_{t-1} - \hat{x}_{t-1|t-1})(x_{t-1} \\ &\quad - \hat{x}_{t-1|t-1})^T] F^T + E[w_t w_t^T] \\ &\Rightarrow P_{t|t-1} = F P_{t-1|t-1} F^T + Q_t. \end{aligned}$$

Уравнения измерения измерений даются формулой

$$\hat{x}_{t|t} = \hat{x}_{t|t-1} + K_t(z_t - H_t \hat{x}_{t|t-1}) \quad (5)$$

$$P_{t|t} = P_{t|t-1} - K_t H_t P_{t|t-1} \quad (6)$$

Где

$$K_t = P_{t|t-1} H_t^T (H_t P_{t|t-1} H_t^T + R_t)^{-1} \quad (7)$$

В оставшейся части этой статьи мы выведем уравнения изменения измерения [(5) - (7)] из первых принципов.

РЕШЕНИЕ


Фильтр Калмана будет получен здесь, при рассмотрении простой одномерной проблемы отслеживания, в частности, что поезд движется вдоль железнодорожной линии. В каждую эпоху измерений мы хотим

ЛУЧШУЮ ОЦЕНКУ МЫ МОЖЕМ СДЕЛАТЬ КОМБИНИРОВАНИЕМ НАШИХ ЗНАНИЙ ИЗ ПРОГНОЗИРОВАНИЯ И ИЗМЕРЕНИЯ.

знать наилучшую возможную оценку местоположения поезда (точнее, расположение радиопередатчика, установленной на крыше поезда). Информация доступна из двух источников:

1) прогнозы, основанные на последнем известном положении и скорости движения поезда

2) измерения системы радиопередатчика, развернутой со стороны дороги. Информация из прогнозов и измерений объединяется, чтобы обеспечить наилучшую возможную оценку местоположения поезда. Система показана графически на рисунке 1. Исходное состояние системы (в момент времени $t = 0$) известно с достаточной точностью, как показано на рисунке 2. Расположение поезда задается Гауссовым ФПВ. В следующий раз ($t=1s$), мы можем оценить новое положение поезда на основе известных ограничений, таких как его положение и скорость при $t=0$, его максимальное возможное ускорение и торможение и т. д. На практике мы можем иметь некоторое знание управляющих входов на тормоз или ускоритель водителем. В любом случае у нас есть прогноз новой позиции поезда, представленный на рисунке 3 новым Гауссовским ФПВ с новым средним значением и дисперсией. Математически этот шаг представлен (1). Дисперсия увеличилась [см. (2)], что представляет нашу пониженную



[Рис.3] Здесь показано предсказание местоположения поезда в момент времени $t = 1$ и уровень неопределенности в этом прогнозе. Уверенность в знании положения поезда уменьшилась, так как мы не уверены, что поезд претерпел какие-либо ускорения или замедления в промежуточный период от $t = 0$ до $t = 1$.

определенность в точности нашей оценки положения по сравнению с $t = 0$ из-за неопределенности, связанной с любым шумом процесса от ускорений или замедлений, проведенных с момента времени $t = 0$ до времени $t = 1$.

При $t=1$ мы также измеряем местоположение поезда с использованием системы позиционирования радиосигнала, и это представлено синим Гауссовым ФПВ на рисунке 4. Наилучшая оценка, которую мы можем сделать относительно местоположения поезда, обеспечивается сочетая наши знания с предсказанием и измерением. Это достигается путем умножения двух соответствующих файлов ФПВ вместе. Это представлено зеленой ФПВ на рисунке 5.

В этой области используется ключевое свойство Гауссовой функции: произведение двух Гауссовых функций является новой функцией Гаусса. Это имеет решающее значение, так как позволяет бесконечно умножать Гауссовские ФПВ - файлы с течением времени, но результирующая функция не увеличивает сложность или количество операций; после каждой эпохи новый ФПВ полностью представлен Гауссовой функцией. Это

ключ к элегантным рекурсивным свойствам фильтра Калмана. Этапы, описанные выше на рисунках, теперь снова математически рассматриваются для получения уравнений фильтра Калмана. Предсказание ФПВ, представленное красной Гауссовой функцией на рисунке 3, задается уравнением

$$y_1(r; \mu_1, \sigma_1) \doteq \frac{1}{\sqrt{2\pi\sigma_1^2}} e^{-\frac{(r-\mu_1)^2}{2\sigma_1^2}} \quad (8)$$

Измерение ФПВ, представленное голубой Гауссовой функцией на рисунке 4, дается формулой

$$y_2(r; \mu_2, \sigma_2) \doteq \frac{1}{\sqrt{2\pi\sigma_2^2}} e^{-\frac{(r-\mu_2)^2}{2\sigma_2^2}} \quad (9)$$

Информация, предоставленная этими двумя ФПВ-файлами, соединяется путем умножения двух элементов, т.е. с учетом предсказания и измерения (см. Рисунок 5). Новая ФПВ, представляет собой слияние

ОСНОВНОЕ СВОЙСТВО ФУНКЦИИ ГАУССА ГЛАСИТ: ПРОИЗВЕДЕНИЕ ДВУХ ФУНКЦИЙ ГАУССА РАВНО НОВОЙ ФУНКЦИИ ГАУССА.

информация от предсказания и измерения и нашу лучшую текущую оценку системы, следовательно, дается произведением этих двух Гауссовских функций

$$\begin{aligned} y_{\text{fused}}(r; \mu_1, \sigma_1, \mu_2, \sigma_2) &= \frac{1}{\sqrt{2\pi\sigma_1^2}} e^{-\frac{(r-\mu_1)^2}{2\sigma_1^2}} \times \frac{1}{\sqrt{2\pi\sigma_2^2}} e^{-\frac{(r-\mu_2)^2}{2\sigma_2^2}} \\ &= \frac{1}{2\pi\sqrt{\sigma_1^2\sigma_2^2}} e^{-\left(\frac{(r-\mu_1)^2}{2\sigma_1^2} + \frac{(r-\mu_2)^2}{2\sigma_2^2}\right)} \quad (10) \end{aligned}$$

Квадратичные члены этой новой функции могут быть расширены, а затем все выражение переписано в Гауссовой форме

$$y_{\text{fused}}(r; \mu_{\text{fused}}, \sigma_{\text{fused}}) = \frac{1}{\sqrt{2\pi\sigma_{\text{fused}}^2}} e^{-\frac{(r-\mu_{\text{fused}})^2}{2\sigma_{\text{fused}}^2}} \quad (11)$$

Где


$$\begin{aligned} \mu_{\text{fused}} &= \frac{\mu_1\sigma_2^2 + \mu_2\sigma_1^2}{\sigma_1^2 + \sigma_2^2} \\ &= \mu_1 + \frac{\sigma_1^2(\mu_2 - \mu_1)}{\sigma_1^2 + \sigma_2^2} \quad (12) \end{aligned}$$

И


$$\sigma_{\text{fused}}^2 = \frac{\sigma_1^2\sigma_2^2}{\sigma_1^2 + \sigma_2^2} = \sigma_1^2 - \frac{\sigma_1^4}{\sigma_1^2 + \sigma_2^2} \quad (13)$$

Эти последние два уравнения представляют собой шаги обновления измерения алгоритма фильтра Кальмана, как это будет явно показано ниже. Однако это для представления более общего случая, а нам нужно рассмотреть расширение этого примера.

В приведенном выше примере предполагалось что предсказания и измерения были сделаны в одной и той же системе координат и в тех же единицах. Это привело к в особенно сжатой паре уравнения,



[Рис.4] Показывает измерение местоположения поезда в момент времени $t = 1$ и уровень неопределенности в этом шумовом измерении, представленный синим гауссовским ФПВ. Совокупное знание этой системы обеспечивается путем умножения этих двух ФПВ функций.



[Рис.5] Показывает новую ФПВ (зеленый), созданный путем умножения ФПВ, связанных с предсказанием и измерением местоположения поезда в момент времени $t = 1$. Эта новая ФПВ дает наилучшую оценку местоположения поезда, объединяя данные из предсказания и измерения.

представляющие предсказание и этапы обновления. Это важно, однако, обычно требуется функция для отображения прогнозов и измерений в той же области. В более реалистичном нашем примере, положение поезда будет предсказано непосредственно как новое состояние по железнодорожной линии в метрах, а время - записывается в секундах.

Чтобы обеспечить прогнозирование и измерение, один должен быть преобразован в область другого, и стандартная практика сопоставить предсказания и измерения через преобразование матрицы Ht.

Перейдем теперь к рассмотрению (8) и (9), y1 и y2 представим в метрах по железной дороге, мы рассмотрим распределение y2 для представления время движения в секундах для радио сигнала, распространяющегося от передатчика, расположенного в точке x = 0 на антенне на

поезде. Пространственное предсказание ФПВ y1 является вершиной в области измерения посредством масштабирования функции на скорость. Поэтому уравнения (8) и (9) должны

переписаться как

$$y_1(s; \mu_1, \sigma_1, c) \triangleq \frac{1}{\sqrt{2\pi(\frac{\sigma_1}{c})^2}} e^{-\frac{(s - \frac{\mu_1}{c})^2}{2(\frac{\sigma_1}{c})^2}} \quad (14)$$

И

$$y_2(s; \mu_2, \sigma_2) \triangleq \frac{1}{\sqrt{2\pi\sigma_2^2}} e^{-\frac{(s - \mu_2)^2}{2\sigma_2^2}} \quad (15)$$

где оба распределения теперь определены в области измерения, радиосигналы распространяются вдоль оси времени «с», а единица измерения - секунды. Наблюдая за дифференцированием по-прежнему, мы теперь находим

$$\begin{aligned} \frac{\mu_{fused}}{c} &= \frac{\mu_1}{c} + \frac{(\frac{\sigma_1}{c})^2 (\mu_2 - \frac{\mu_1}{c})}{(\frac{\sigma_1}{c})^2 + \sigma_2^2} \\ \Rightarrow \mu_{fused} &= \mu_1 + \left(\frac{\frac{\sigma_1^2}{c}}{(\frac{\sigma_1}{c})^2 + \sigma_2^2} \right) (\mu_2 - \frac{\mu_1}{c}) \end{aligned} \quad (16)$$

Подставляя H=1/c и K=(Hσ1²)/(H²σ1²+σ2²) получим

$$\mu_{fused} = \mu_1 + K \cdot (\mu_2 - H\mu_1) \quad (17)$$

Аналогично, оценка объединённой дисперсии становится

$$\begin{aligned} \frac{\sigma_{fused}^2}{c^2} &= \left(\frac{\sigma_1}{c}\right)^2 - \frac{\left(\frac{\sigma_1}{c}\right)^4}{\left(\frac{\sigma_1}{c}\right)^2 + \sigma_2^2} \\ \Rightarrow \sigma_{fused}^2 &= \sigma_1^2 - \left(\frac{\frac{\sigma_1^2}{c}}{\left(\frac{\sigma_1}{c}\right)^2 + \sigma_2^2}\right) \sigma_1^2 \\ &= \sigma_1^2 - KH\sigma_1^2 \end{aligned} \quad (18)$$

ФИЛЬТР КАЛМАНА МОЖЕТ БЫТЬ ПОЛУЧЕН С ИСПОЛЬЗОВАНИЕМ ПРОСТОЙ СКАЛЯРНОЙ МАТЕМАТИКИ, СЛЕДУЯ ЛОГИКЕ И ПРОВЕДЯ МЫСЛЕННОЕ ИССЛЕДОВАНИЕ

Теперь мы можем сравнить некоторые термины, полученные в результате этого скалярного вывода со стандартными векторами и матрицами, используемыми в алгоритме фильтра Калмана:

- $\mu_{fused} \rightarrow \hat{x}_{t|t}$: вектор состояния после объединения данных
- $\mu_1 \rightarrow \hat{x}_{t|t-1}$: вектор состояния перед объединением данных, то есть предсказание
- $\sigma_{fused}^2 \rightarrow P_{t|t}$: матрица ковариации (достоверность) после объединения данных
- $\sigma_1^2 \rightarrow P_{t|t-1}$: ковариационная матрица (достоверность) до объединения данных
- $\mu_2 \rightarrow z_t$: вектор измерения
- $\sigma_2^2 \rightarrow R_t$: матрица неопределенности, связанная с шумовым набором измерений

■ H - Ht: матрица преобразования, используемая для отображения параметров состояния вектора в область измерения

$$\begin{aligned} K &= \frac{H\sigma_1^2}{H^2\sigma_1^2 + \sigma_2^2} \rightarrow K_t \\ &= P_{t|t-1} H_t^T (H_t P_{t|t-1} H_t^T + R_t)^{-1}; \end{aligned}$$

Коэффициент Калмана

Теперь легко понять, как стандартные уравнения фильтра Калмана относятся к (17) и (18), выведенным выше:

$$\begin{aligned} \mu_{fused} &= \mu_1 + \left(\frac{H\sigma_1^2}{H^2\sigma_1^2 + \sigma_2^2} \right) (\mu_2 - H\mu_1) \\ \rightarrow \hat{x}_{t|t} &= \hat{x}_{t|t-1} + K_t (z_t - H_t \hat{x}_{t|t-1}) \\ \sigma_{fused}^2 &= \sigma_1^2 - \left(\frac{H\sigma_1^2}{H^2\sigma_1^2 + \sigma_2^2} \right) H\sigma_1^2 \\ \rightarrow P_{t|t} &= P_{t|t-1} - K_t H_t P_{t|t-1} \end{aligned}$$

ВЫВОДЫ

Фильтру Калмана можно обучить с помощью простого вывода, включающего скалярную математику, основные алгебраические манипуляции и простой в использовании мысленный эксперимент. Такой подход должен позволить студентам, не имеющим сильных математических навыков, понять интуитивно основную математику, лежащую в основе фильтра Калмана, и понять, что рекурсивное свойство фильтра обеспечивается уникальным мультипликативным свойством функции Гаусса.

АВТОР

Рамси Фарахер (ramsey@cantab.net)

является главным ученым в BAESystems

Advanced Technology Center, Великобритания.

ССЫЛКИ

- [1] B. D. O. Anderson and J. B. Moore, Optimal Filtering. New York: Dover, 2005.
- [2] R. E. Kalman, "A new approach to linear filtering and prediction problems," J. Basic Eng., vol. 82, no.

[3] P. D. Groves, Principles of GNSS, Inertial, and Multisensor Integrated Navigation Systems.

Norwood, MA: Artech House, 2008.

[4] S. J. Julier and J. K. Uhlmann, "Unscented filtering and nonlinear estimation,"

Proc. IEEE, vol. 92, no. 3, pp. 401–422, 2004.

[5] J. Bibby and H. Toutenburg, Prediction and

Improved Estimation in Linear Models. New York:

Wiley, 1977.