

Теория систем массового обслуживания

Теория массового обслуживания опирается на теорию вероятностей и математическую статистику.

При исследовании операций часто приходится сталкиваться с системами, предназначенными для многоразового использования при решении однотипных задач. Возникающие при этом процессы получили название *процессов обслуживания*, а системы — *систем массового обслуживания (СМО)*. Примерами таких систем являются телефонные системы, ремонтные мастерские, вычислительные комплексы, билетные кассы, магазины, парикмахерские и т.п.

Каждая СМО состоит из определенного числа обслуживающих единиц (приборов, устройств, пунктов, станций), которые будем называть *каналами обслуживания*. Каналами могут быть линии связи, рабочие точки, вычислительные машины, продавцы и др. По числу каналов СМО подразделяют на *одноканальные* и *многоканальные*.

Заявки поступают в СМО обычно не регулярно, а случайно, образуя так называемый *случайный поток заявок (требований)*. Обслуживание заявок, вообще говоря, также продолжается какое-то случайное время. Случайный характер потока заявок и времени обслуживания приводит к тому, что СМО оказывается загруженной неравномерно: в какие-то периоды времени скапливается очень большое количество заявок (они либо становятся в очередь, либо покидают СМО необслуженными), в другие же периоды СМО работает с недогрузкой или простаивает.

Предметом теории массового обслуживания является построение математических моделей, связывающих заданные условия работы СМО (число каналов, их производительность, характер потока заявок и т.п.) с показателями эффективности СМО, описывающими ее способность справляться с потоком заявок.

В качестве *показателей эффективности СМО* используются: среднее число заявок, обслуживаемых в единицу времени; среднее число заявок в очереди; среднее время ожидания обслуживания; вероятность отказа в

обслуживании без ожидания; вероятность того, что число заявок в очереди превысит определенное значение и т.п.

СМО делят на два основных типа (класса): **СМО с отказами** и **СМО с ожиданием (очередью)**. В СМО с отказами заявка, поступившая в момент, когда все каналы заняты, получает отказ, покидает СМО и в дальнейшем процессе обслуживания не участвует (например, заявка на телефонный разговор в момент, когда все каналы заняты, получает отказ и покидает СМО необслуженной). В СМО с ожиданием заявка, пришедшая в момент, когда все каналы заняты, не уходит, а становится в очередь на обслуживание.

СМО с ожиданием подразделяются на разные виды в зависимости от того, как организована очередь: с ограниченной или неограниченной длиной очереди, с ограниченным временем ожидания и т.п.

Для классификации СМО важное значение имеет **дисциплина обслуживания**, определяющая порядок выбора заявок из числа поступивших и порядок распределения их между свободными каналами. По этому признаку обслуживание заявки может быть организовано по принципу "первая пришла — первая обслужена", "последняя пришла — первая обслужена" (такой порядок может применяться, например, при извлечении для обслуживания изделий со склада, ибо последние из них оказываются часто более доступными) или обслуживание с приоритетом (когда в первую очередь обслуживаются наиболее важные заявки). Приоритет может быть как **абсолютным**, когда более важная заявка "вытесняет" из-под обслуживания обычную заявку (например, в случае аварийной ситуации плановые работы ремонтных бригад прерываются до ликвидации аварии), так и **относительным**, когда более важная заявка получает лишь "лучшее" место в очереди.

Процесс работы СМО представляет собой **случайный процесс**.

Под **случайным (вероятностным или стохастическим) процессом** понимается процесс изменения во времени состояния какой-либо системы в соответствии с вероятностными закономерностями.

Процесс называется **процессом с дискретными состояниями**, если его возможные состояния S_1, S_2, \dots, S_n можно заранее перечислить, а переход

системы из состояния в состояние происходит мгновенно (скачком). Процесс называется *процессом с непрерывным временем*, если моменты возможных переходов системы из состояния в состояние не фиксированы заранее, а случайны.

Процесс работы СМО представляет собой случайный процесс с дискретными состояниями и непрерывным временем. Это означает, что состояние СМО меняется скачком в случайные моменты появления каких-то событий (например, прихода новой заявки, окончания обслуживания и т.п.).

Математический анализ работы СМО существенно упрощается, если процесс этой работы — марковский. Случайный процесс называется *марковским* или *случайным процессом без последствия*, если для любого момента времени t_0 вероятностные характеристики процесса в будущем зависят только от его состояния в данный момент t_0 и не зависят от того, когда и как система пришла в это состояние.

Пример марковского процесса: система S — счетчик в такси. Состояние системы в момент t характеризуется числом километров (десятых долей километров), пройденных автомобилем до данного момента. Пусть в момент t_0 счетчик показывает S_0 . Вероятность того, что в момент $t > t_0$ счетчик покажет то или иное число километров (точнее, соответствующее число рублей) S_1 , зависит от S_0 , но не зависит от того, в какие моменты времени изменялись показания счетчика до момента t_0 .

Многие процессы можно приближенно считать марковскими. Например, процесс игры в шахматы; система S — группа шахматных фигур. Состояние системы характеризуется числом фигур противника, сохранившихся на доске в момент t_0 . Вероятность того, что в момент $t > t_0$ материальный перевес будет на стороне одного из противников, зависит в первую очередь от того, в каком состоянии находится система в данный момент t_0 , а не от того, когда и в какой последовательности исчезли фигуры с доски до момента t_0 .

В ряде случаев предысторией рассматриваемых процессов можно просто пренебречь и применять для их изучения марковские модели.

При анализе случайных процессов с дискретными состояниями удобно пользоваться геометрической схемой — так называемым *графом состояний*. Обычно состояния системы изображаются прямоугольниками (кружками), а возможные переходы из состояния в состояние — стрелками (ориентированными дугами), соединяющими состояния.

Для математического описания марковского случайного процесса с дискретными состояниями и непрерывным временем, протекающего в СМО, познакомимся с одним из важных понятий теории вероятностей — понятием потока событий.

Под *потоком событий* понимается последовательность однородных событий, следующих одно за другим в какие-то случайные моменты времени (например, поток вызовов на телефонной станции, поток отказов ЭВМ, поток покупателей и т.п.).

Поток характеризуется *интенсивностью* λ — частотой появления событий или средним числом событий, поступающих в СМО в единицу времени.

Поток событий называется *регулярным*, если события следуют одно за другим через определенные равные промежутки времени. Например, поток изделий на конвейере сборочного цеха (с постоянной скоростью движения) является регулярным.

Поток событий называется *стационарным*, если его вероятностные характеристики не зависят от времени. В частности, интенсивность стационарного потока есть величина постоянная: $\lambda(t)=\lambda$. Например, поток автомобилей на городском проспекте не является стационарным в течение суток, но этот поток можно считать стационарным в течение суток, скажем, в часы пик. Обращаем внимание на то, что в последнем случае фактическое число проходящих автомобилей в единицу времени (например, в каждую минуту) может заметно отличаться друг от друга, но среднее их число будет постоянно и не будет зависеть от времени.

Поток событий называется *потоком без последствия*, если для любых двух непересекающихся участков времени τ_1 и τ_2 — число событий,

попадающих на один из них, не зависит от числа событий, попадающих на другие. Например, поток пассажиров, входящих в метро, практически не имеет последствия. А, скажем, поток покупателей, отходящих с покупками от прилавка, уже имеет последствие (хотя бы потому, что интервал времени между отдельными покупателями не может быть меньше, чем минимальное время обслуживания каждого из них).

Поток событий называется **ординарным**, если вероятность попадания на малый (элементарный) участок времени Δt двух и более событий пренебрежимо мала по сравнению с вероятностью попадания одного события. Другими словами, поток событий ординарен, если события появляются в нем поодиночке, а не группами. Например, поток поездов, подходящих к станции, ординарен, а поток вагонов не ординарен.

Поток событий называется **простейшим** (или **стационарным пуассоновским**), если он одновременно стационарен, ординарен и не имеет последствия. Название "простейший" объясняется тем, что СМО с простейшими потоками имеет наиболее простое математическое описание. Заметим, что регулярный поток не является "простейшим", так как он обладает последствием: моменты появления событий в таком потоке жестко зафиксированы.

Простейший поток в качестве предельного возникает в теории случайных процессов столь же естественно, как в теории вероятностей нормальное распределение получается в качестве предельного для суммы случайных величин: при наложении (суперпозиции) достаточно большого числа n независимых, стационарных и ординарных потоков (сравнимых между собой по интенсивностям λ_i ($i=1,2,\dots,n$)) получается поток, близкий к простейшему с интенсивностью λ , равной сумме интенсивностей входящих потоков, т.е. $\lambda = \sum_{i=1}^n \lambda_i$. Рассмотрим на оси времени Ot простейший поток событий как неограниченную последовательность случайных точек.



Можно показать, что для простейшего потока число m событий (точек), попадающих на произвольный участок времени τ , распределено по **закону Пуассона** $P_m(\tau) = ((\lambda\tau)^m / m!) e^{-\lambda\tau}$, для которого математическое ожидание случайной величины равно ее дисперсии: $a = \sigma^2 = \lambda\tau$.

В частности, вероятность того, что за время τ не произойдет ни одного события ($m=0$), равна $P_0(\tau) = e^{-\lambda\tau}$. Найдем распределение интервала времени T между произвольными двумя соседними событиями простейшего потока. Вероятность того, что на участке времени длиной t не появится ни одного из последующих событий, равна $P(T \geq t) = e^{-\lambda t}$, а вероятность противоположного события, т.е. функция распределения случайной величины T , есть $F(t) = P(T < t) = 1 - e^{-\lambda t}$.

Плотность вероятности случайной величины есть производная ее функции распределения, т.е. $\varphi(t) = F'(t) = \lambda e^{-\lambda t}$.

Распределение, задаваемое плотностью вероятности или функцией распределения, называется **показательным** (или **экспоненциальным**). Таким образом, интервал времени между двумя соседними произвольными событиями имеет показательное распределение, для которого математическое ожидание равно среднему квадратическому отклонению случайной величины $a = \sigma = 1/\lambda$ и обратно по величине интенсивности потока λ .

Важнейшее свойство показательного распределения (присущее только показательному распределению) состоит в следующем: если промежуток времени, распределенный по показательному закону, уже длился некоторое время τ , то это никак не влияет на закон распределения оставшейся части промежутка ($T - \tau$): он будет таким же, как и закон распределения всего промежутка T .

Другими словами, для интервала времени T между двумя последовательными соседними событиями потока, имеющего показательное распределение, любые сведения о том, сколько времени протекал этот интервал, не влияют на закон распределения оставшейся части. Это свойство показательного закона представляет собой, в сущности, другую формулировку для "отсутствия последействия" — основного свойства простейшего потока.

Для простейшего потока с интенсивностью λ вероятность попадания на *элементарный (малый)* отрезок времени Δt хотя бы одного события потока равна согласно $P\Delta t = P(T < \Delta t) = 1 - e^{-\lambda\Delta t} \approx \lambda\Delta t$.

Заметим, что эта приближенная формула, получаемая заменой функции $e^{-\lambda\Delta t}$ лишь двумя первыми членами ее разложения в ряд по степеням Δt , тем точнее, чем меньше Δt .

На первичное развитие теории массового обслуживания оказали особое влияние работы датского ученого А.К. Эрланга (1878-1929).

Теория массового обслуживания – область прикладной математики, занимающаяся анализом процессов в системах производства, обслуживания, управления, в которых однородные события повторяются многократно, например, на предприятиях бытового обслуживания; в системах приема, переработки и передачи информации; автоматических линиях производства и др.

Предметом теории массового обслуживания является установление зависимостей между характером потока заявок, числом каналов обслуживания, производительностью отдельного канала и эффективным обслуживанием с целью нахождения наилучших путей управления этими процессами.

Задача теории массового обслуживания – установить зависимость результирующих показателей работы системы массового обслуживания (вероятности того, что заявка будет обслужена; математического ожидания числа обслуженных заявок и т.д.) от входных показателей (количества каналов в системе, параметров входящего потока заявок и т.д.). Результирующими показателями или интересующими нас характеристиками СМО являются – показатели эффективности СМО, которые описывают способна ли данная система справиться с потоком заявок.

Задачи теории массового обслуживания носят оптимизационный характер и в конечном итоге включают экономический аспект по определению такого варианта системы, при котором будет обеспечен минимум суммарных затрат от ожидания обслуживания, потерь времени и ресурсов на обслуживание и

простоев каналов обслуживания.

Система обслуживания считается заданной, если известны:

- 1) поток требований, его характер;
- 2) множество обслуживающих приборов;
- 3) дисциплина обслуживания (совокупность правил, задающих процесс обслуживания).

Каждая СМО состоит из какого-то числа обслуживающих единиц, которые называются каналами обслуживания. В качестве каналов могут фигурировать: линии связи, различные приборы, лица, выполняющие те или иные операции и т.п.

Всякая СМО предназначена для обслуживания какого-то потока заявок, поступающих в какие-то случайные моменты времени. Обслуживание заявок продолжается какое-то случайное время, после чего канал освобождается и готов к приему следующей заявки. Случайный характер потока заявок и времен обслуживания приводит к тому, что в какие-то периоды времени на входе СМО скапливается излишне большое число заявок (они либо становятся в очередь, либо покидают СМО не обслуженными); в другие же периоды СМО будет работать с недогрузкой или вообще простаивать.

Процесс работы СМО представляет собой случайный процесс с дискретными состояниями и непрерывным временем; состояние СМО меняется скачком в моменты появления каких-то событий (или прихода новой заявки, или окончания обслуживания, или момента, когда заявка, которой надоело ждать, покидает очередь).

Перечень характеристик систем массового обслуживания можно представить следующим образом:

- среднее время обслуживания;
- среднее время ожидания в очереди;
- среднее время пребывания в СМО;
- средняя длина очереди;
- среднее число заявок в СМО;
- количество каналов обслуживания;

- интенсивность входного потока заявок;
- интенсивность обслуживания;
- интенсивность нагрузки;
- коэффициент нагрузки;
- относительная пропускная способность;
- абсолютная пропускная способность;
- доля времени простоя СМО;
- доля обслуженных заявок;
- доля потерянных заявок;
- среднее число занятых каналов;
- среднее число свободных каналов;
- коэффициент загрузки каналов;
- среднее время простоя каналов.

Для облегчения процесса моделирования используют классификацию СМО по различным признакам, для которых пригодны определенные группы методов и моделей теории массового обслуживания, упрощающие подбор адекватных математических моделей к решению задач обслуживания в коммерческой деятельности.

СМО с ожиданием — в общем случае многоканальная система в которую поступает поток заявок с интенсивностью λ ; интенсивность обслуживания μ (т. е. в среднем непрерывно занятый канал будет выдавать $\frac{\lambda}{\mu}$ обслуженных заявок в единицу (времени). Заявка, поступившая в момент, когда канал занят, становится в очередь и ожидает обслуживания.

Система с ограниченной длиной очереди. Предположим сначала, что количество мест в очереди ограничено числом m , т. е. если заявка пришла в момент, когда в очереди уже стоят m заявок, она покидает систему необслуженной. В дальнейшем, устремив m к бесконечности, мы получим характеристики одноканальной СМО без ограничений длины очереди.

Будем нумеровать состояния СМО по числу заявок, находящихся в системе (как обслуживаемых, так и ожидающих обслуживания):

S_0 —канал свободен; S_1 —канал занят, очереди нет;

S_2 — канал занят, одна заявка стоит в очереди;

S_k —канал занят, $k - 1$ заявок стоят в очереди;

S_{m+1} — канал занят, k заявок стоят в очереди.

Граф системы показан на рис. 1.2. Все интенсивности потоков событий, переводящих в систему по стрелкам слева направо, равны λ , а справа налево — μ . Действительно, по стрелкам слева направо систему переводит поток заявок (как только придет заявка, система переходит в следующее состояние), справа же налево — поток «освобождений» занятого канала, имеющий интенсивность μ (как только будет обслужена очередная заявка, канал либо освободится, либо уменьшится число заявок в очереди).




Рис. 1.2. Одноканальная СМО с ожиданием

Изображенная на рис. 1.2 схема представляет собой схему размножения и гибели. Используя общее решение (1.1)—(1. 4), напишем выражения для предельных вероятностей состояний:

$$\begin{cases} p_k = \left(\frac{\lambda}{\mu}\right)^k p_0; (k=1, 2, \dots, m+1); \\ p_0 = \frac{1}{1 + \left(\frac{\lambda}{\mu}\right) + \left(\frac{\lambda}{\mu}\right)^2 + \dots + \left(\frac{\lambda}{\mu}\right)^{m+1}} \end{cases} \quad (1.1)$$

или с использованием $p_k = \frac{\lambda}{\mu}$:

$$\begin{cases} p_k = p^k p_0; (k=1, 2, \dots, m+1); \\ p_0 = \frac{1}{1 + p + p^2 + \dots + p^{m+1}} = (1 + p + p^2 + \dots + p^{m+1})^{-1} \end{cases} \quad (1.2)$$

Последняя строка в (1.2) содержит геометрическую прогрессию с первым членом 1 и знаменателем p ; откуда получаем:

$$p_0 = \frac{1}{(1 - p^{m+2}) / (1 - p)} = \frac{1 - p}{1 - p^{m+2}} \quad (1.3)$$

в связи с чем предельные вероятности принимают вид:

$$\begin{cases} p_0 = \frac{1-p}{1-p^{m+2}} \\ p_1 = \rho p_0; \\ p_2 = \rho^2 p_0; \\ \dots \\ p_k = \rho^k p_0; \\ p_{m+1} = \rho^{m+1} p_0 \end{cases} \quad (1.4)$$

Выражение (1.4) справедливо только при $\rho < 1$ (при $\rho = 1$ она дает неопределенность вида $0/0$). Сумма геометрической прогрессии со знаменателем $\rho = 1$ равна $m + 2$, и в этом случае

$$p_0 = \frac{1}{m+2}$$

Определим характеристики СМО: вероятность отказа $P_{отк}$, относительную пропускную способность q , абсолютную пропускную способность A , среднюю длину очереди \bar{r} , среднее число заявок, связанных с системой \bar{k} , среднее время ожидания в очереди $\bar{t}_{ож}$, среднее время пребывания заявки в СМО $\bar{t}_{смо}$.

Вероятность отказа. Очевидно, заявка получает отказ только в случае, когда канал занят и все m мест в очереди тоже:

$$P_{отк} = p_{m+1} = \frac{p^{m+1}(1-p)}{1-p^{m+2}} \quad (1.5)$$

Относительная пропускная способность:

$$q = 1 - P_{отк} = 1 - \frac{p^{m+1}(1-p)}{1-p^{m+2}} \quad (1.6)$$

Абсолютная пропускная способность:

$$A = \lambda q$$

Средняя длина очереди. Найдем среднее число \bar{r} заявок, находящихся в очереди, как математическое ожидание дискретной случайной величины R — числа заявок, находящихся в очереди:

$$\bar{r} = M[R]$$

С вероятностью p_2 в очереди стоит одна заявка, с вероятностью p_3 — две заявки, вообще с вероятностью p_k в очереди стоят $k - 1$ заявок, и т. д., откуда:

$$\bar{r} = M[R] = \sum_{k=2}^{m+1} p^k p_0 = p^2 p_0 \sum_{k=2}^{m+1} (k-1) p^{k-2} = p^2 p_0 \sum_{k=1}^m k p^{k-1} \quad (1.7)$$

Поскольку $k p^{k-1} = \frac{d p^k}{d p}$, сумму в (1.7) можно трактовать как производную

порот суммы геометрической прогрессии:

$$\sum_{k=1}^m k p^{k-1} = i$$

Подставляя данное выражение в (1.7) и используя p_0 из (1.4), окончательно получаем:

$$\bar{r} = \frac{p^2(1-(m+1-mp)p^m)}{(1-p)(1-p^{m+2})} \quad (1.8)$$

Среднее число заявок, находящихся в системе. Получим далее формулу для среднего числа \bar{k} заявок, связанных с системой (как стоящих в очереди, так и находящихся на обслуживании). Поскольку $\bar{k} = \bar{r} + \bar{w}$, где \bar{w} — среднее число заявок, находящихся под обслуживанием, а k известно, то остается определить \bar{w} . Поскольку канал один, число обслуживаемых заявок может равняться 0 (с вероятностью p_0) или 1 (с вероятностью $1 - p_0$), откуда:

$$\bar{w} = 0 \cdot p_0 + 1 \cdot (1 - p_0) = \frac{p - p^{m+2}}{1 - p^{m+2}}$$

и среднее число заявок, связанных с СМО, равно

$$\bar{k} = \bar{r} + \frac{p - p^{m+2}}{1 - p^{m+2}} \quad (1.9)$$

Среднее время ожидания заявки в очереди. Обозначим его $\bar{t}_{ож}$; если заявка приходит в систему в какой-то момент времени, то с вероятностью p_0 канал обслуживания не будет занят, и ей не придется стоять в очереди (время ожидания равно нулю). С вероятностью P_1 она придет в систему во время обслуживания какой-то заявки, но перед ней не будет очереди, и заявка будет ждать начала своего обслуживания в течение времени $1/\mu$ (среднее время обслуживания одной заявки). С вероятностью P_2 в очереди перед рассматриваемой заявкой будет стоять еще одна, и время ожидания в среднем будет равно $2/\mu$, и т. д.

Если же $k = m + 1$, т. е. когда вновь входящая заявка застаёт канал обслуживания занятым и m заявок в очереди (вероятность этого P_{m+1}), то в этом случае заявка не становится в очередь (и не обслуживается), поэтому время ожидания равно нулю. Среднее время ожидания будет равно:

$$\bar{t}_{ож} = p_1 \frac{1}{\mu} + p_2 \frac{2}{\mu} + \dots + p_k \frac{k}{\mu} + \dots + p_m \frac{m}{\mu}$$

если подставить сюда выражения для вероятностей (1.4), получим:

$$\bar{t}_{ож} = p_0 p \frac{1}{\mu} + p_0 p^2 \frac{2}{\mu} + \dots + p_0 p_k \frac{k}{\mu} + \dots + p_0 p_m \frac{m}{\mu} = \frac{p_0 p}{\mu} \frac{(1 - (m+1-p)p^m)}{(1-p)^2} = \frac{p}{\mu} \frac{(1 - (m+1-p)p^m)}{(1-p)(1-p^{m+2})} \quad (1.10)$$

Здесь использованы соотношения (1.7), (1.10) (производная геометрической прогрессии), а также p_0 из (1.4). Сравнивая это выражение с (1.10), замечаем, что иначе говоря, среднее время ожидания равно среднему числу заявок в очереди, деленному на интенсивность потока заявок.

$$\bar{t}_{ож} = \frac{1}{p\mu} \bar{r} = \frac{\bar{r}}{\lambda} \quad (1.11)$$

Среднее время пребывания заявки в системе. Обозначим $(\bar{t}_{смо})$ матожидание случайной величины — время пребывания заявки в СМО, которое складывается из среднего времени ожидания в очереди $(\bar{t}_{ож})$ и среднего времени обслуживания $(\bar{t}_{обсл})$. Если загрузка системы составляет 100 %, очевидно, $\bar{t}_{обсл} = 1/\mu$, в противном же случае

$$\bar{t}_{обсл} = q/\mu$$

Отсюда

$$\bar{t}_{смо} = \bar{t}_{ож} + \bar{t}_{обсл} = \frac{\bar{r}}{\lambda} + \frac{q}{\mu}$$