SEMAINE 6
TRANSPORT

***

*_ Claude CHAUDET_*

Maître de conférences à Télécom ParisTech

***

S1 : Le transport de bout en bout

Vous avez vu, en semaine 5, la façon dont le réseau achemine les trames d'une source à une destination. La couche transport se positionne au-dessus de la couche réseau pour fournir aux applications une interface, un canal de communication, qui leur permettra de communiquer entre elles, sans se préoccuper du fonctionnement exact du réseau.

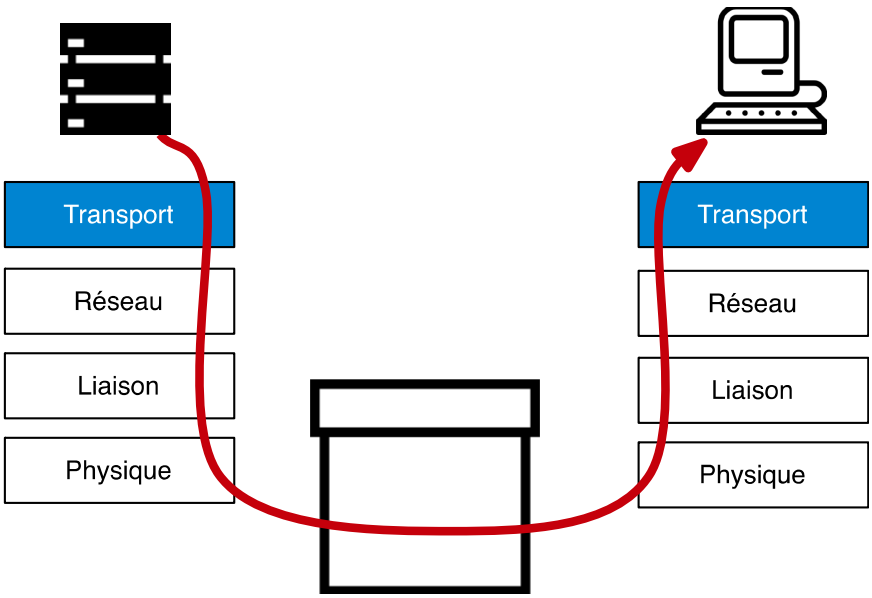

Une application désirant communiquer avec une autre application distante va demander au système d'exploitation qui l'héberge d'ouvrir ce canal de communication à destination de la machine qui accueille l'application réceptrice. Le système d'exploitation va alors se charger de contacter cette

machine, identifiée par son adresse IP et d'ouvrir ce canal de communication sur lequel les applications pourront alors échanger des données.

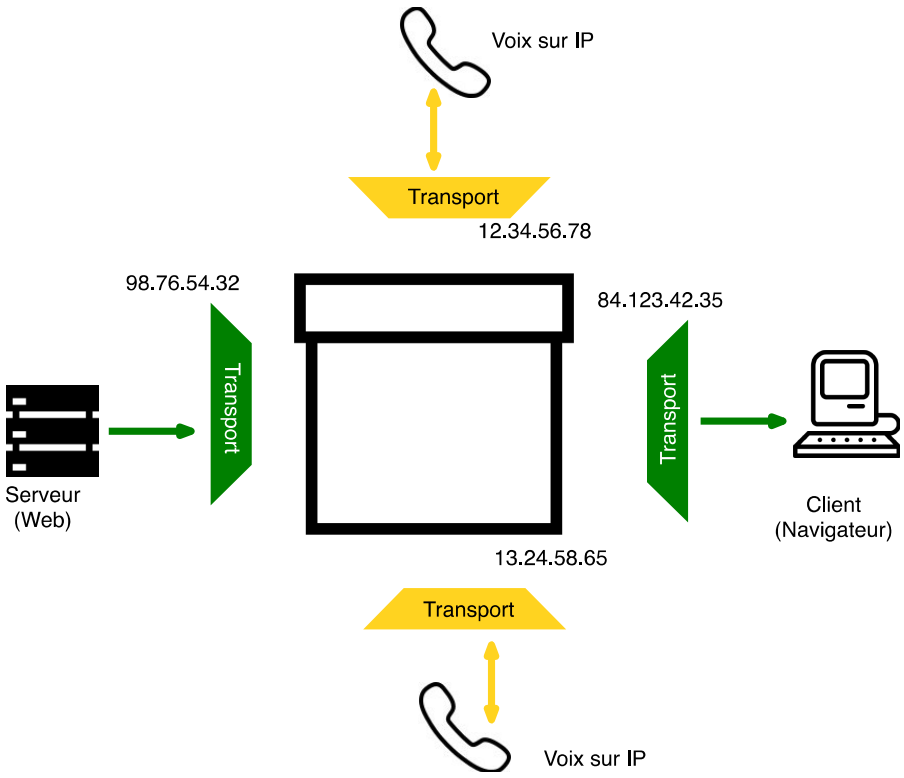

Pour permettre à plusieurs applications de coexister sur la même machine, la couche transport introduit un niveau d'adressage supplémentaire qu'on appelle le numéro de port. Le numéro de port est un simple numéro, sur 16 bits, qui vient s'ajouter à l'adresse IP, permettant ainsi d'identifier une application fonctionnant sur une machine.

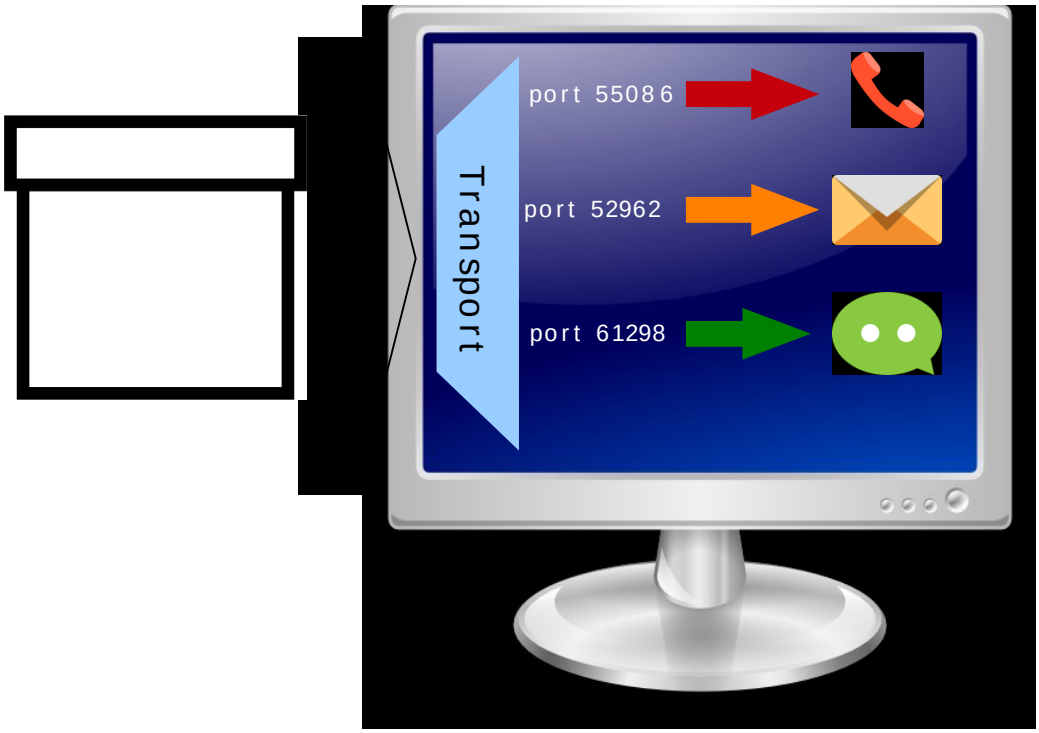

Le système d'exploitation va allouer à une application un ou plusieurs numéros de port de façon exclusive. Aucune autre application ne pourra utiliser le même numéro de port au même moment.

Une application serveur, dont le fonctionnement classique est d'attendre les connexions des applications clientes, va réserver son ou ses numéros de port au moment de son lancement. Une application cliente, dont le fonctionnement est plus dynamique, va réserver son numéro de port au moment où elle fera la demande de connexion vers le serveur distant qu'elle cherche à joindre.

Pour contacter son correspondant, une application va donc envoyer une requête à destination d'un numéro de port prédéterminé. Sa requête contiendra par ailleurs un numéro de port source qui lui servira à recevoir les réponses.

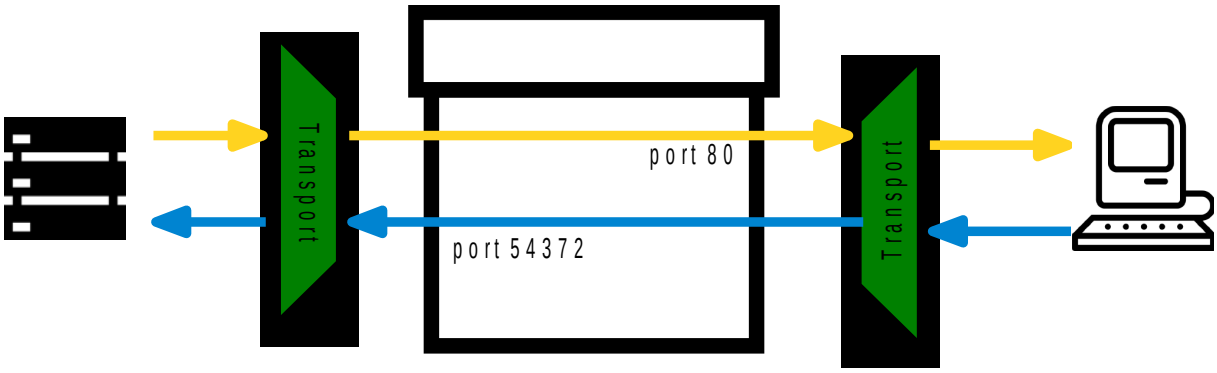

Les numéros de port de 0 à 1023 sont généralement utilisés pour les applications très largement répandues telles que les serveurs web, les serveurs FTP, les serveurs e-mail, etc. Les numéros de port de 1024 à 49151 sont destinés à des applications qui possèdent une, deux ou assez peu d'implémentations et sont déclarées en général auprès d'un organisme central qui s'appelle l'IANA. Les numéros de port de 49152 à 65535 sont réservés à l'usage privé et sont en général utilisés pour recevoir les réponses aux requêtes que l'on envoie.

Numéro de port	Usage	Exemples
Well-known (1 — 1023)	Services et protocoles standard	Web (HTTP) : 80 e-mail (SMTP) : 25 session (SSH) : 22 DNS : 53
Enregistrés (1024 — 49151)	Applications déclarées à l'IANA	Bittorrent : 6881 HTTP proxy : 8080 Quake server : 26000
Dynamiques, privés (49152 — 65535)	Aucune réservation possible	

La couche transport va recevoir, de la part des applications, des données de taille arbitraire. Elle va se charger de découper ces données en blocs d'information de taille conforme à ce que peut acheminer le réseau. Ces blocs d'information se nomment segments ou datagrammes selon le mode utilisé. La

couche transport réceptrice va recevoir ces segments ou ces datagrammes et va les réassembler afin de fournir à l'application réceptrice un flux d'informations cohérent.

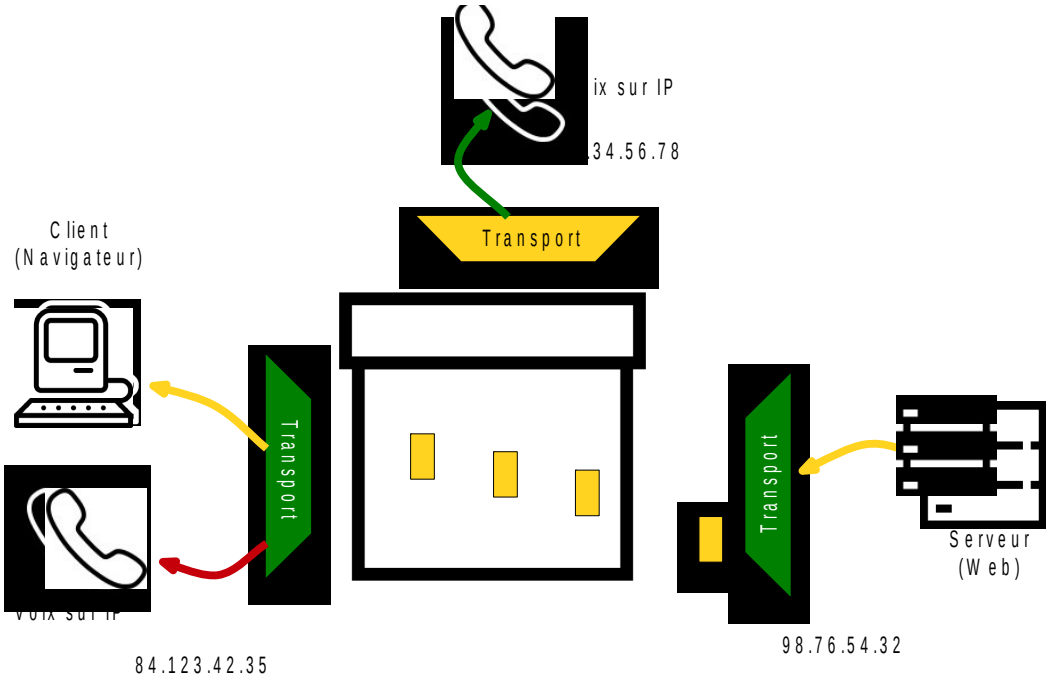

La couche transport crée donc, entre deux applications, un canal de communication que l'on peut voir comme un tuyau possédant certaines propriétés en termes de débit, de délai, de taux de pertes, etc. Ces propriétés dépendent du fonctionnement exact du réseau.

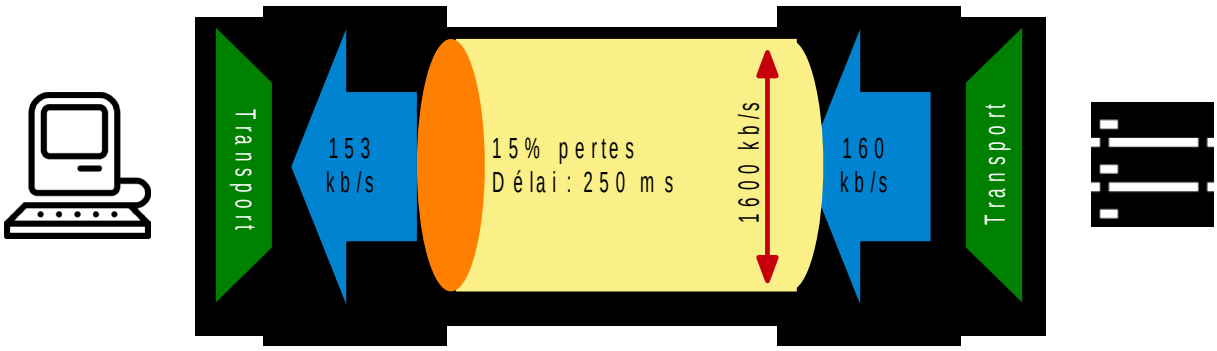

La longueur des chemins empruntés, par exemple, va influencer le délai de bout en bout. Les différentes couches « liaison » successives traversées vont influencer la probabilité de perdre un segment. Une application ne peut pas contrôler ou exiger de la part du réseau un certain niveau de performance, en

ce qui concerne le débit ou le délai en tout cas. En revanche, en sélectionnant le mode de fonctionnement de la couche transport, elle peut demander à la couche transport d'assurer un certain niveau de fiabilité sur la communication.

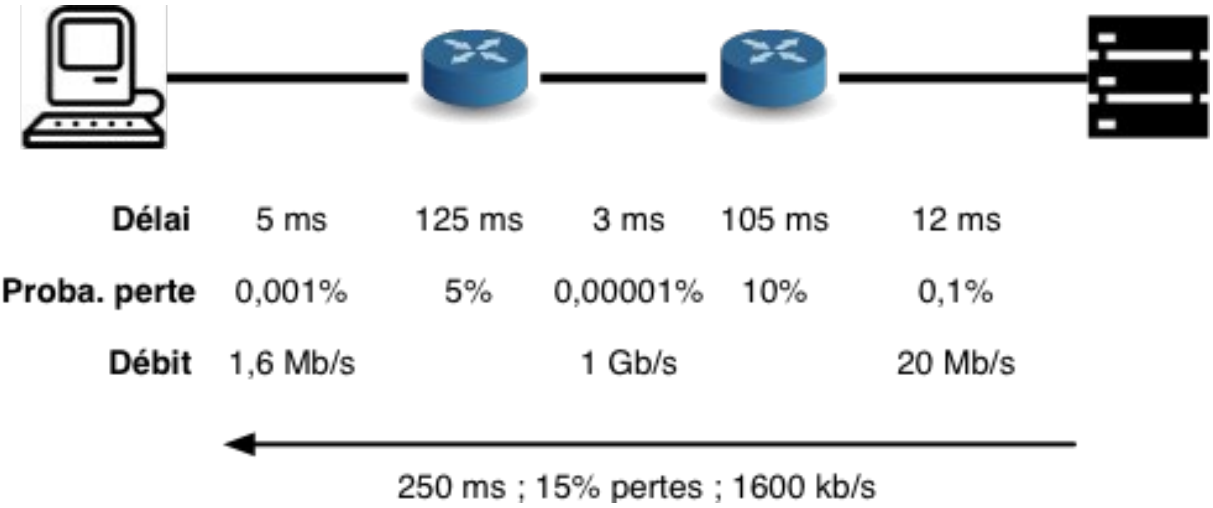

Certaines applications ont besoin de s'assurer que l'intégralité des données qu'elles envoient soit bien reçue par leur correspondant. Ces applications vont utiliser un mode de communication que l'on qualifie de mode connecté et un protocole de transport qui s'appelle TCP. Ce faisant, elles vont demander au système d'exploitation qui les accueille de s'assurer de la bonne réception de l'intégralité des segments envoyés. Le système d'exploitation va, si nécessaire, provoquer des retransmissions des segments qui seraient perdus en cours de route.

Cependant, ce n'est pas le cas de toutes les applications. En effet, pour certaines applications, notamment pour les applications multimédia telles que la vidéoconférence, la voix sur IP ou encore la diffusion audio ou vidéo, une perte d'information se traduit généralement par une baisse momentanée de la qualité. Ces applications préféreront souvent tolérer une telle baisse de qualité plutôt que d'attendre une retransmission d'un segment perdu. En effet, retransmettre un segment perdu prend du temps et ce délai supplémentaire introduit engendre généralement une pause dans la diffusion du flux.

Ces applications n'ont pas besoin que le système d'exploitation se charge d'assurer une transmission fiable à 100%. Elles utiliseront un mode de communication que l'on nomme datagramme et sélectionneront un protocole de transport qui s'appelle UDP.

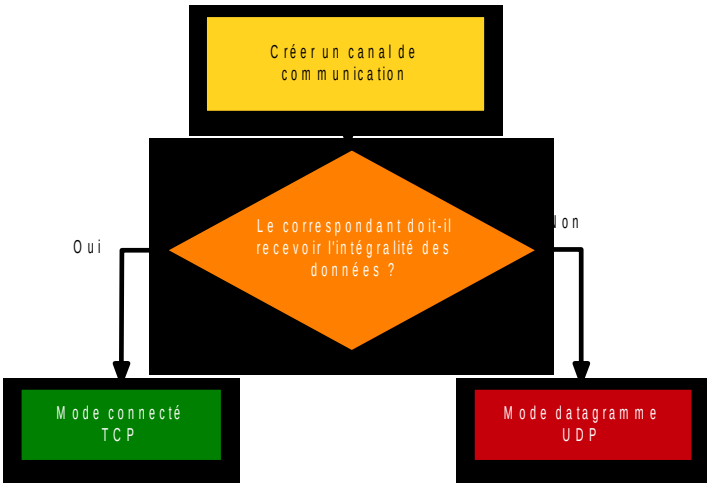

UDP est un protocole de transport minimaliste. Il n'ajoute aux données transmises par les applications que 4 champs. Les deux premiers champs sont les numéros de port source et destination qui identifient l'application émettrice et l'application réceptrice. UDP ajoute, en outre, la longueur des données transmises ainsi qu'une somme de contrôle qui permet de vérifier l'intégrité des données. En effet, si UDP ne provoque aucune retransmission en cas d'erreur, il ne transmet pas aux applications non plus de données erronées.

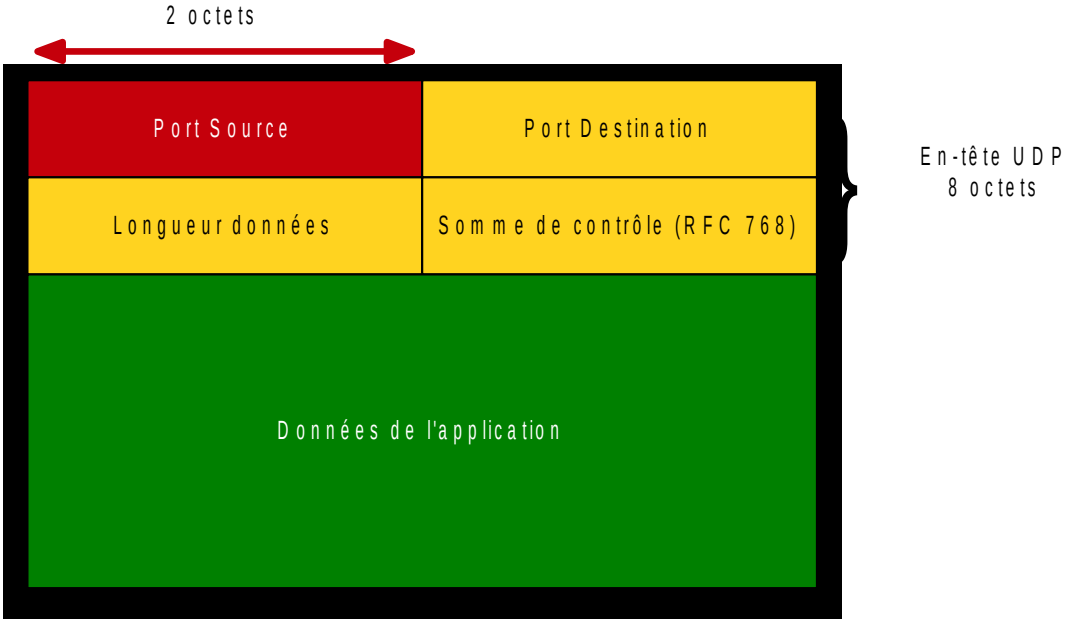

À l'inverse, TCP fournit aux applications une transmission fiable en utilisant une des techniques les plus classiques qui soit : la destination acquittera chacun des segments reçus correctement, et la source, en l'absence de réception d'un

acquittement au bout d'un certain temps, provoquera une retransmission à l'image du protocole du bit alterné que vous avez étudié dans un précédent TP.

Dans cette première séance, nous avons décrit les objectifs et les principes généraux de la couche transport. Nous avons vu les deux modes de communication : mode connecté et mode datagramme, ainsi que les deux protocoles de transport principaux, TCP et UDP. Dans la suite de ce cours, nous nous intéresserons essentiellement à TCP, plus complexe qu'UDP. TCP gère en effet la fiabilité au moyen des acquittements que nous examinerons plus en détail lors de la prochaine séance, et s'assure aussi de ne pas provoquer de congestion dans le réseau, en limitant le débit des flux envoyés.

S2 : Le transport face aux erreurs de transmission

Dans la séance précédente, nous avons introduit les mécanismes de base de la couche transport. Dans cette séance, nous allons nous intéresser à la façon dont TCP gère la fiabilité des communications.

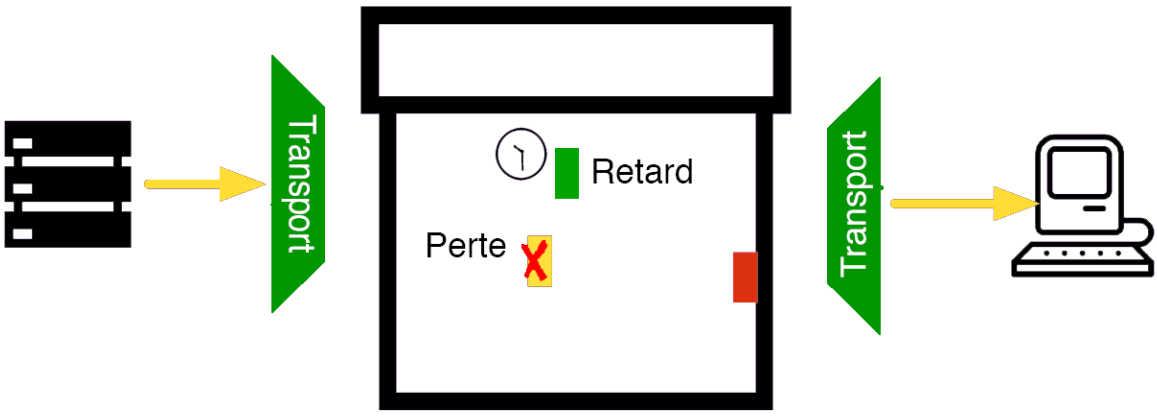

TCP assure aux applications une transmission fiable et ordonnée ; ce qui veut dire que TCP va mettre en œuvre les mécanismes nécessaires à compenser les pertes et les retards introduits par le passage des segments dans le réseau. Les segments peuvent être perdus pour diverses raisons : des erreurs de transmission peuvent survenir sur les liens de communication et, le plus souvent, des paquets vont être perdus dans les files d'attente des routeurs pour des questions de surcharge. TCP va alors s'assurer que l'application émettrice détecte ces pertes de paquets et assure la retransmission des paquets puisqu'elle est la seule à disposer encore et avec certitude de la donnée.

Le récepteur, quant à lui, a pour tâche d'acquitter chaque segment de données qui lui parvient correctement ; c'est-à-dire sans erreur. Il va, à cet effet, envoyer à l'émetteur des acquittements qui sont des paquets IP comme les autres, qui vont transiter par le même réseau que le segment initial. L'émetteur, en l'absence de réception d'un tel acquittement, va conclure que le segment initial est perdu et provoquer une retransmission au bout d'un certain temps.

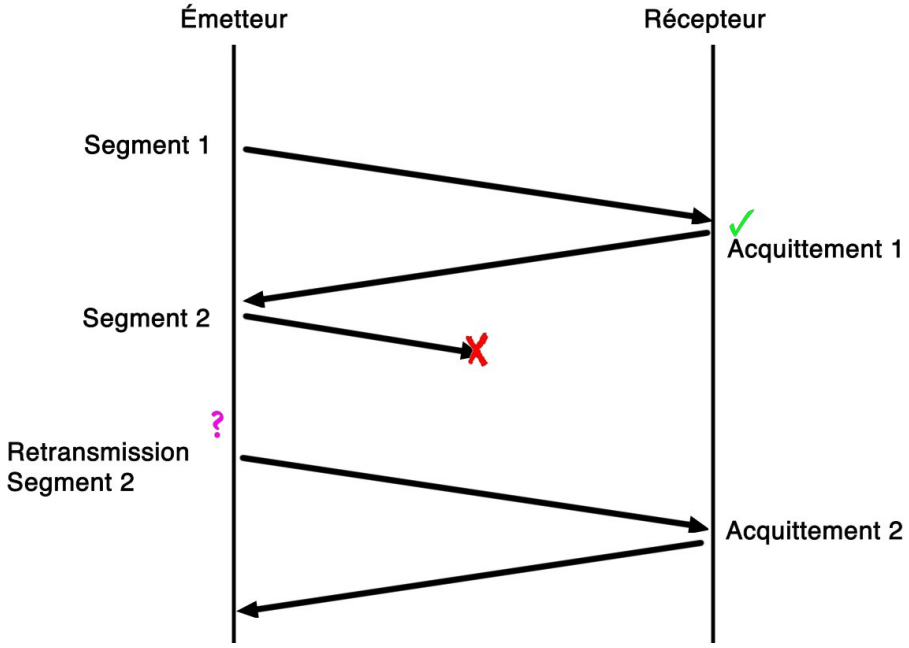

Le récepteur acquitte donc chaque segment de données reçu correctement. Cette stratégie peut sembler inefficace. En effet, il peut sembler plus économe de ne demander explicitement la retransmission que des segments manquants ou erronés. Cependant, ces demandes de retransmission sont des paquets comme les autres et transitent par un réseau imparfait et vont donc être soumis, eux aussi, à des pertes et des retards. Par conséquent, l'utilisation d'acquittements positifs est la seule façon de s'assurer d'une fiabilité à 100% de la réception de l'intégralité des données, même si cette stratégie est moins économique.

Pour pouvoir conclure au succès ou à l'échec d'une transmission, l'émetteur devra estimer le temps au bout duquel il devrait recevoir l'acquittement. Cependant, ceci n'est pas chose facile dans l'Internet car, contrairement à la couche liaison, il n'est pas possible d'utiliser un temporisateur fixe. En effet, le récepteur peut aussi bien être très proche de l'émetteur que très éloigné.

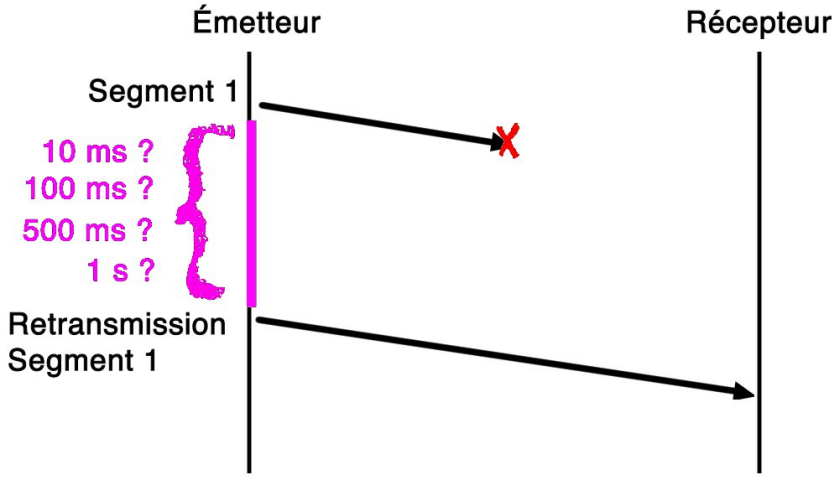

Exemples de délais (depuis Paris) :

Institut Mines-Télécom	: 25 ms	(0 km)
MIT (Boston, MA)	: 20 ms	(5600 km)
Stanford (Californie)	: 180 ms	(9000 km)
IIT Delhi (Inde)	: 250 ms	(6600 km)
Tokyo Insitute of Technology	: 350 ms	(9700 km)
UFRGS (Porto Alegre, Brésil)	: 310 ms	(10200 km)

Un bon dimensionnement du temporisateur qui définit au bout de combien de temps l'émetteur doit recevoir l'acquittement est primordial pour assurer une bonne performance du réseau. En effet, un dimensionnement trop court de ce temporisateur, comme sur l'exemple de la figure de gauche, conduit à provoquer des retransmissions inutiles. En effet, ici, l'acquittement arrive après qu'a été prise la décision de retransmettre un paquet. À l'inverse, si le temporisateur est trop long, comme sur la figure de droite, l'émetteur patientera très longtemps avant de prendre la décision de retransmettre un paquet qu'il aurait dû retransmettre. C'est donc le récepteur qui patientera jusqu'à la bonne transmission de ce paquet.

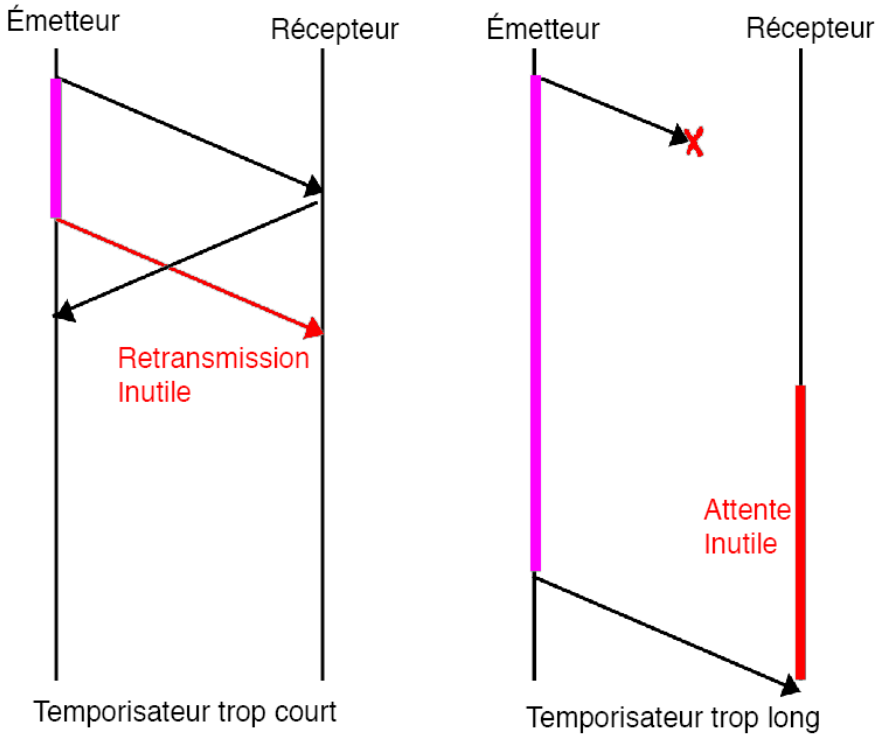

Dans un réseau, une source et une destination peuvent être très proches comme très lointaines. Par conséquent, le temps nécessaire à acheminer un paquet de la source à la destination et à acheminer l'acquittement correspondant de la destination à la source peut être de l'ordre de quelques millisecondes, comme de l'ordre de quelques secondes. Dans ces conditions, il est impossible de dimensionner un temporisateur de manière statique. C'est pourquoi TCP, qui a été conçu pour l'Internet au départ, adopte un dimensionnement dynamique de ce temporisateur, basé sur des statistiques réalisées sur les paquets.

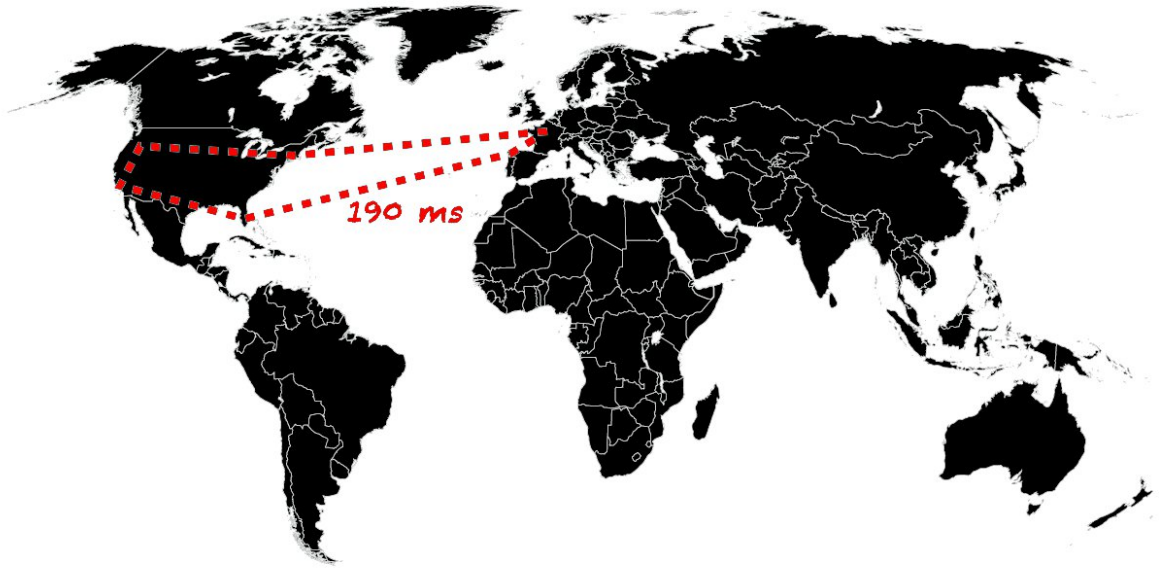

Pour bien dimensionner son temporisateur, TCP va se baser sur une estimation du délai d'aller-retour séparant l'émetteur et le récepteur. Le délai d'aller-retour est défini comme le temps séparant l'envoi d'un segment de la réception de l'acquittement correspondant. TCP va essayer d'estimer une moyenne de ce délai, mais ne va pas réaliser cette moyenne sur l'intégralité des segments depuis le début de la transmission, mais plutôt sur les quelques derniers segments de la transmission.

Sur ce graphique, la courbe bleue représente le délai réel d'aller-retour entre un émetteur et un récepteur. La courbe rouge représente la moyenne calculée par TCP sur un historique récent. On peut remarquer que le temporisateur d'acquittement ne peut pas être égal à la moyenne. En effet, de nombreux acquittements mettent un temps supérieur à cette moyenne pour revenir à l'émetteur. Les segments correspondants seraient alors considérés comme perdus (point orange). C'est pourquoi TCP ajoute à cette moyenne une estimation de la variation du délai pour calculer son temporisateur.

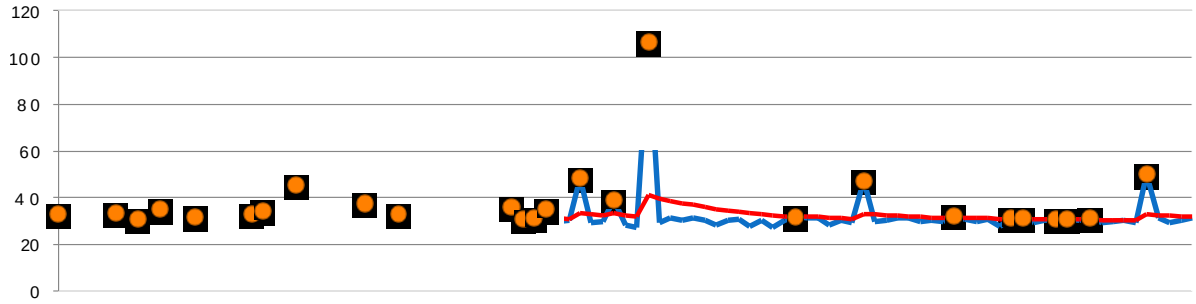

Le temporisateur est, en pratique, égal à la moyenne plus quatre fois l'écart moyen à cette moyenne. Cette formule fera l'objet d'un exercice. La courbe orange, sur ce graphique, représente l'évolution du temporisateur au cours du temps. On peut voir que beaucoup moins de segments sont considérés comme perdus. On peut aussi constater que ne conserver qu'un historique récent permet de s'adapter rapidement aux variations du délai.

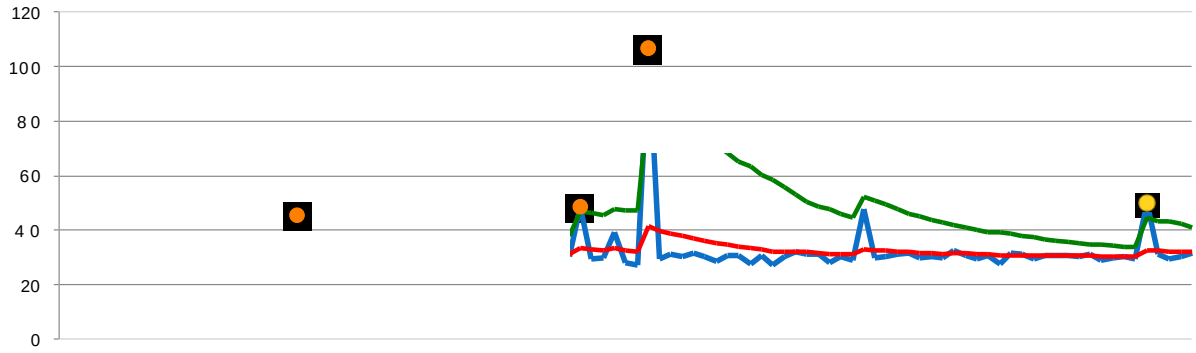

Nous avons vu, dans cette séance, que TCP utilise des acquittements pour s'assurer de la bonne réception des segments de données, mais aussi pour s'adapter aux variations des conditions du réseau. TCP est capable de détecter si un segment a été bien reçu ou perdu. Cependant, cela ne suffit pas pour s'assurer de la bonne réception de l'intégralité de l'information. Nous verrons dans la prochaine séance comment TCP y parvient.

S3 : La session TCP : démarrer et terminer un dialogue

Nous avons vu, dans la séance précédente, que TCP utilisait les acquittements pour s'assurer de la bonne réception des segments. Un émetteur envoie dans le réseau une séquence de segments et reçoit en retour une séquence d'acquittements. Cependant, les segments, comme les acquittements, sont des paquets IP qui transitent dans le réseau. Ils peuvent donc être retardés et rien ne garantit que l'ordre dans lequel les acquittements seront reçus corresponde

bien à l'ordre dans lequel les segments ont été envoyés. Nous allons voir dans cette séance comment TCP procède pour savoir quel segment retransmettre en cas d'erreur.

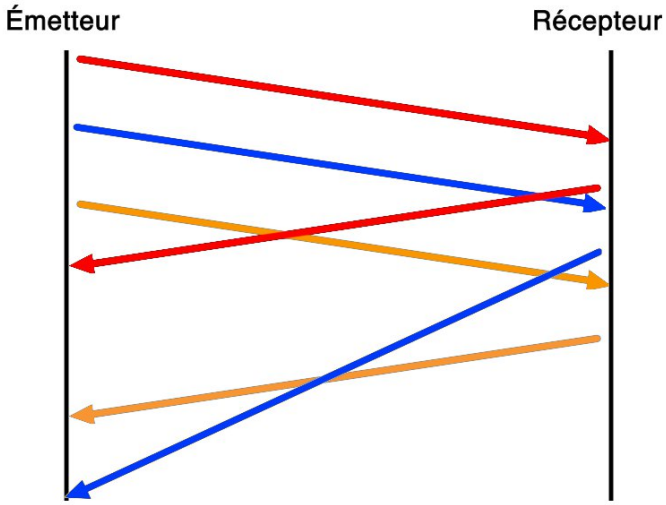

Pour faire correspondre les acquittements aux segments, TCP associe à chaque segment un numéro de séquence auquel l'acquittement correspondant fera référence. En pratique, ce numéro de séquence est l'index du premier octet contenu dans le segment. Ces index sont calculés à partir du premier octet du premier segment du flux de données. L'index initial, quant à lui, est tiré aléatoirement. Il pourrait sembler plus logique de démarrer cette numérotation à 1. Cependant, cette stratégie serait source d'ambiguïté dans certains cas ; notamment lorsque plusieurs essais successifs d'un flux très court sont réalisés.

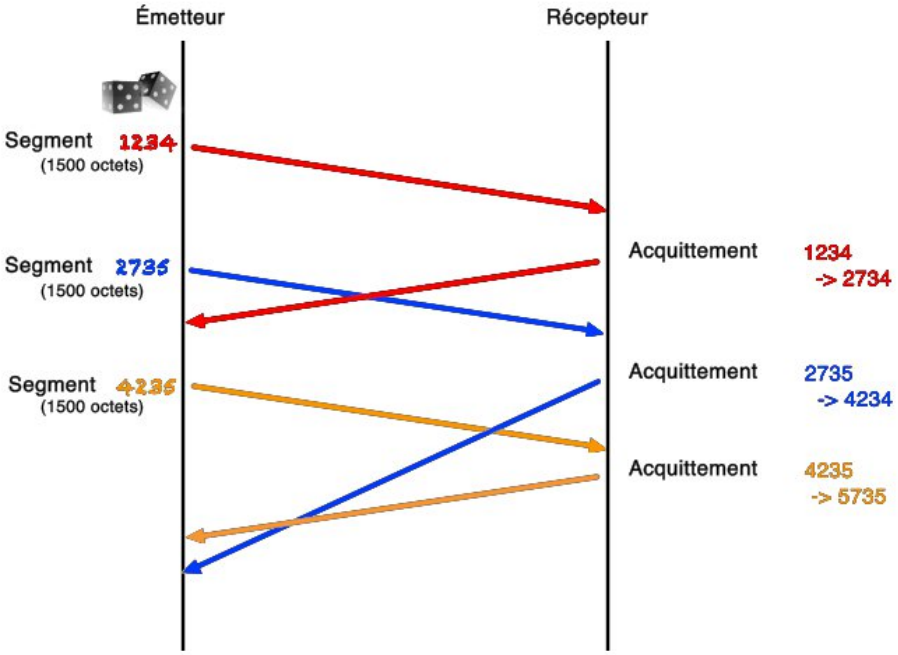

Avec ces numéros de séquence, le récepteur d'un flux TCP sait détecter la présence de trous dans la transmission. En effet, s'il a reçu l'intégralité du flux jusqu'à l'octet numéro *n*, le segment suivant doit démarrer à l'octet *n+1*. Cependant, il doit encore s'assurer d'avoir reçu correctement le début et la fin du flux de données. En effet, les numéros de séquence initiaux et finaux sont arbitraires et l'émetteur doit donc les communiquer explicitement au récepteur. C'est pourquoi TCP impose une phase explicite d'ouverture de connexion et une phase explicite de fermeture de connexion.

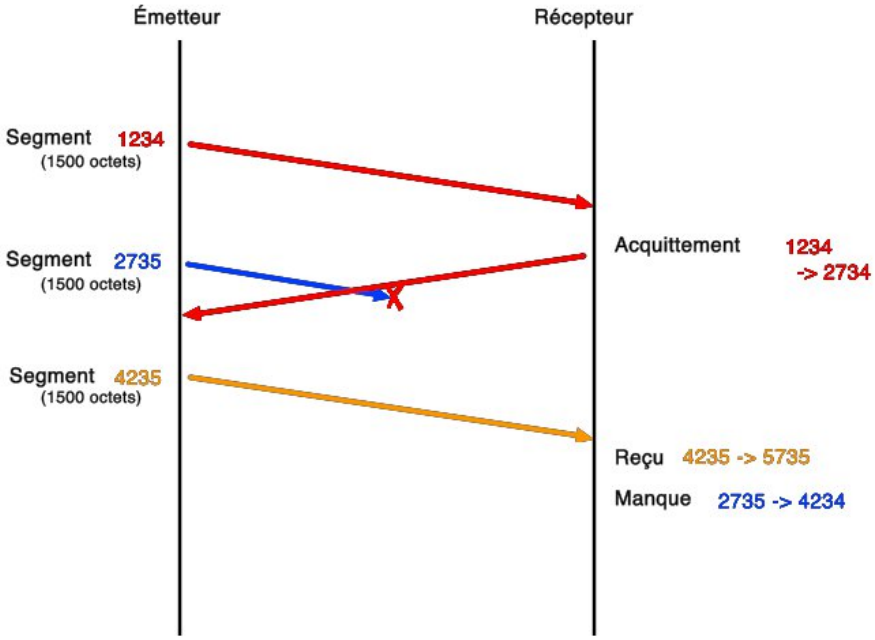

La phase d'ouverture de connexion est composée de 3 messages. Le premier message, appelé synchronisation, est émis par l'initiateur de la connexion. Prenons l'exemple du dialogue entre un navigateur web et un serveur. Le navigateur démarre cet échange en émettant ce message de synchronisation dans lequel il inclura son numéro de séquence initial. Le serveur lui répondra en acquittant la réception de ce numéro de séquence et en incluant dans ce message d'acquittement son propre numéro de séquence initial. En effet, une connexion TCP est toujours ouverte dans les 2 sens et les deux flux de données sont, du point de vue de TCP, indépendants. Leurs numéros de séquence ne sont donc pas alignés. À la réception de ce 2e message, le navigateur renverra au serveur un dernier acquittement et l'échange pourra alors commencer.

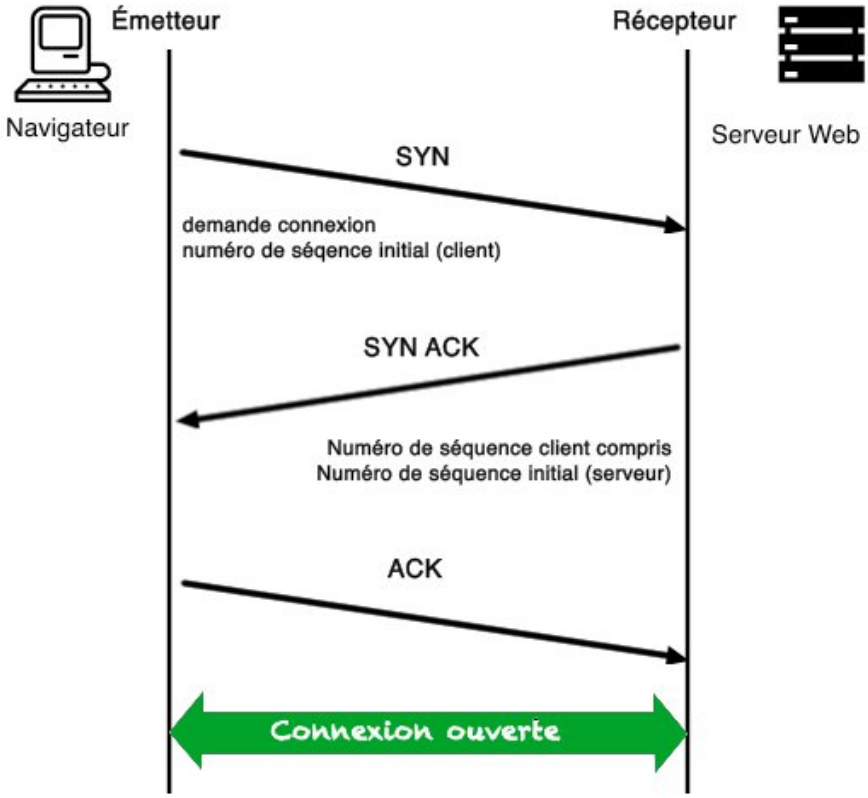

Une fois que le navigateur a terminé la transmission de ses données, il envoie au serveur un message de fin. Ce message contient le dernier numéro de séquence des données plus un. À la réception de ce message, le serveur peut vérifier qu'il a bien reçu l'intégralité des données et, le cas échéant, enverra au navigateur un message d'acquittement. La connexion est alors fermée dans le sens navigateur vers serveur. Elle reste cependant ouverte dans le sens serveur vers navigateur et devra être fermée de manière analogue à l'initiative du serveur.

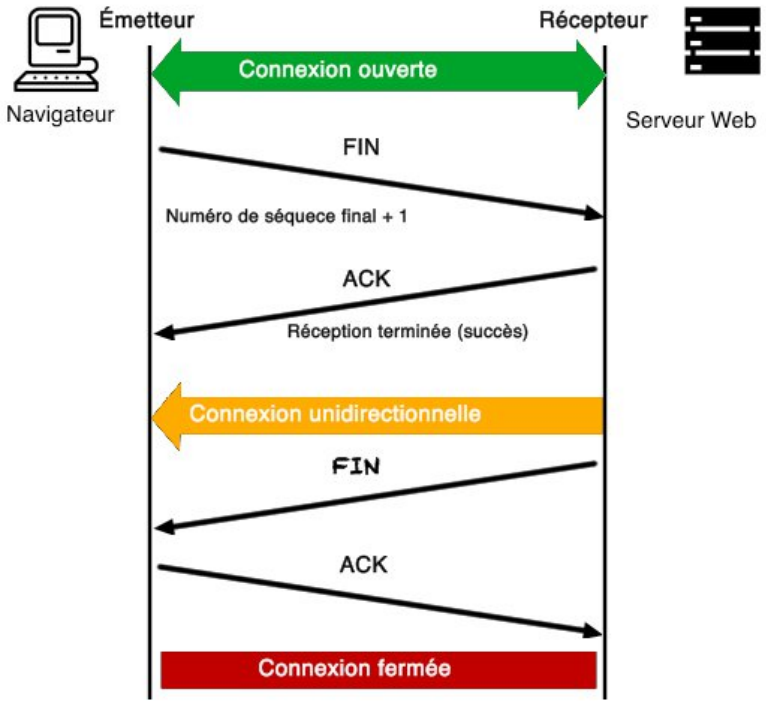

Nous avons vu comment un émetteur TCP s'assurait de la bonne réception de l'intégralité des données qu'il envoie. En pratique, ce jeu d'envoi de données indexées et d'acquittements est réalisée grâce à l'en-tête TCP dont voici un extrait. Vous pouvez noter la place et la taille du numéro de séquence et du numéro d'acquittement. Les phases d'ouverture de connexion et de fin de connexion sont, elles aussi, réalisées au moyen de cet en-tête. En pratique, on envoie un segment de données vide dans lequel des drapeaux sont positionnés pour indiquer s'il s'agit d'un message de synchronisation, d'acquittement ou de fin.

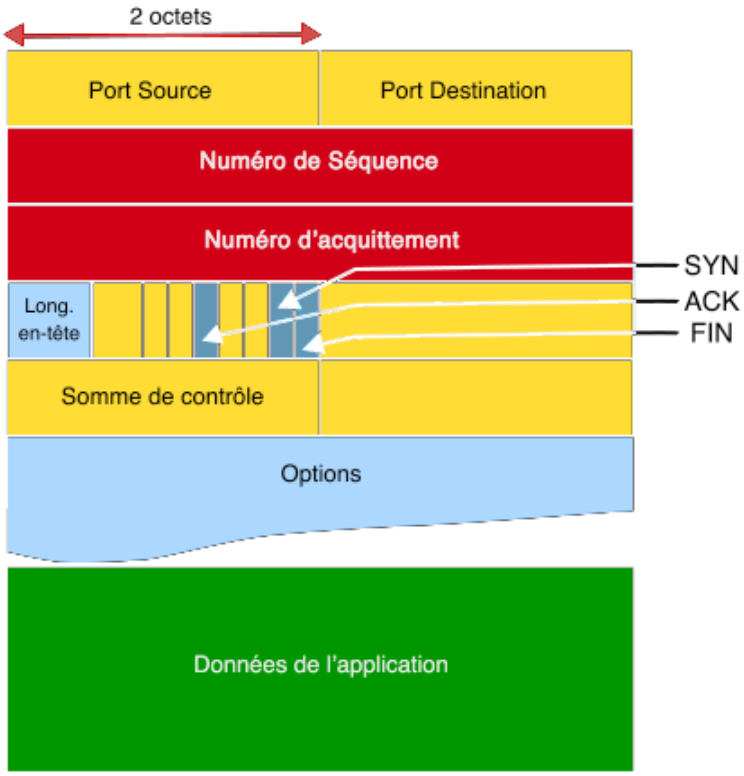

Dans cette séance, nous avons vu comment TCP utilisait les numéros de séquence pour s'assurer de la bonne réception de l'intégralité des données. Nous avons aussi évoqué les phases d'ouverture et de fermeture de connexion. Dans la prochaine séance, nous allons étudier le 2e grand volet de TCP qui est le contrôle de congestion.

S4 : Le contrôle de congestion

Nous avons vu, dans les séances précédentes, que TCP utilise des acquittements pour s'assurer de la fiabilité des communications. Nous avons aussi vu que TCP adapte dynamiquement le temporisateur d'acquittement aux conditions variables d'un réseau qu'il ne connaît pas. TCP cherche à réaliser le bon compromis entre efficacité et volume de trafic supplémentaire généré par les retransmissions. C'est pour maintenir cet équilibre que les sources TCP vont adapter leur débit dynamiquement selon un jeu d'algorithmes que l'on appelle contrôle de congestion.

Revenons sur le comportement d'un émetteur ayant envoyé un segment dans le réseau. Si cet émetteur patiente jusqu'à la réception de l'acquittement correspondant avant d'envoyer le segment suivant, la performance de la communication sera très faible. En effet, émettre ce segment sur le premier lien de communication prend un temps faible ; en Ethernet, de l'ordre de quelques dizaines de microsecondes. En revanche, le délai d'aller-retour, nécessaire à la réception de l'acquittement, est beaucoup plus important : de l'ordre de quelques centaines de millisecondes. Par conséquent, un émetteur qui patienterait jusqu'à la réception de l'acquittement n'utiliserait qu'une très faible proportion de la capacité du lien auquel il est directement connecté.

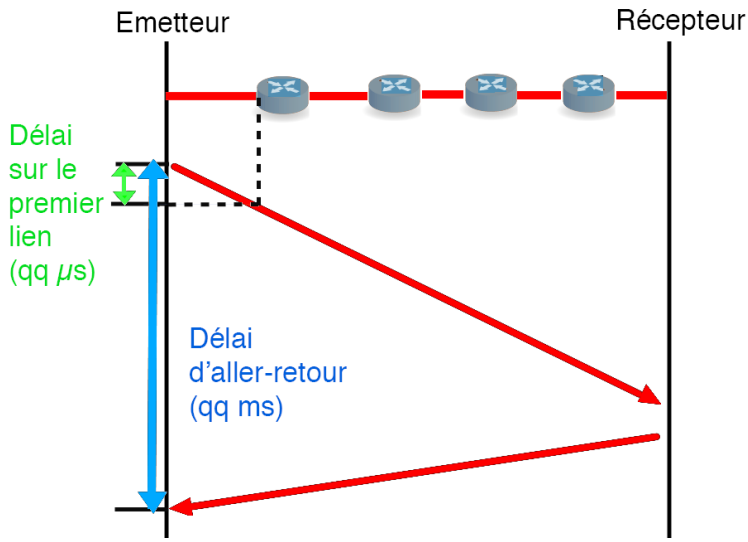

Le produit entre la capacité du réseau séparant un émetteur et un récepteur, exprimée en bit/s, et le délai d'aller-retour entre cet émetteur et ce récepteur, se nomme « produit bande passante x délai ». Ce produit représente le volume

de données qu'il est possible de laisser transiter dans le réseau avant de s'attendre à recevoir le premier acquittement. TCP va adapter dynamiquement le rythme des sources afin de chercher à s'approcher le plus possible de ce produit bande passante x délai.

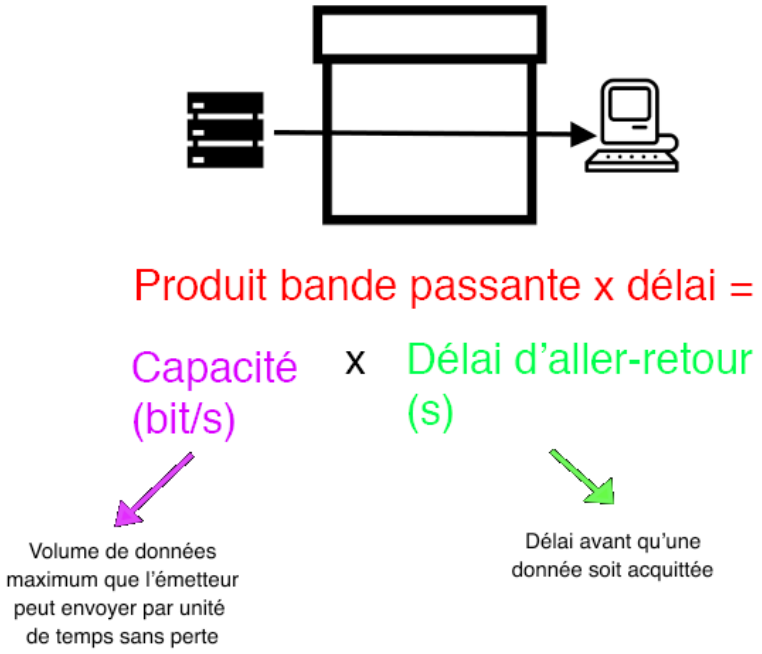

TCP maintient à cet effet une fenêtre que l'on appelle fenêtre de congestion. Cette fenêtre de congestion, dont la valeur est exprimée en octets, s'adapte dynamiquement aux conditions variables du réseau. En d'autres termes, TCP va modifier le débit des sources afin de s'adapter au mieux au lien le plus faible dans le réseau : le goulet d'étranglement.

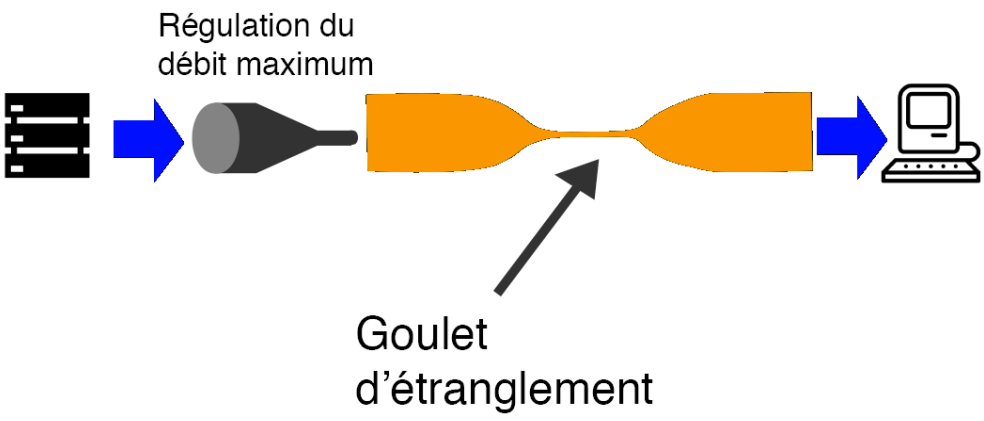

Il est inutile d'essayer de transférer, dans le réseau, des données à un débit supérieur à la capacité du goulet d'étranglement. En effet, dans ce cas, des paquets s'accumuleraient dans le réseau, et plus particulièrement dans les équipements d'interconnexion, provoquant une congestion. La conséquence d'une congestion est que les équipements d'interconnexion verraient leur mémoire tampon saturée et commenceraient à supprimer des paquets, provoquant ainsi des pertes. Les paquets qui ne seraient pas supprimés passeraient beaucoup de temps dans les files d'attente et seraient retardés, au risque de voir leur temporisateur d'acquittement expirer.

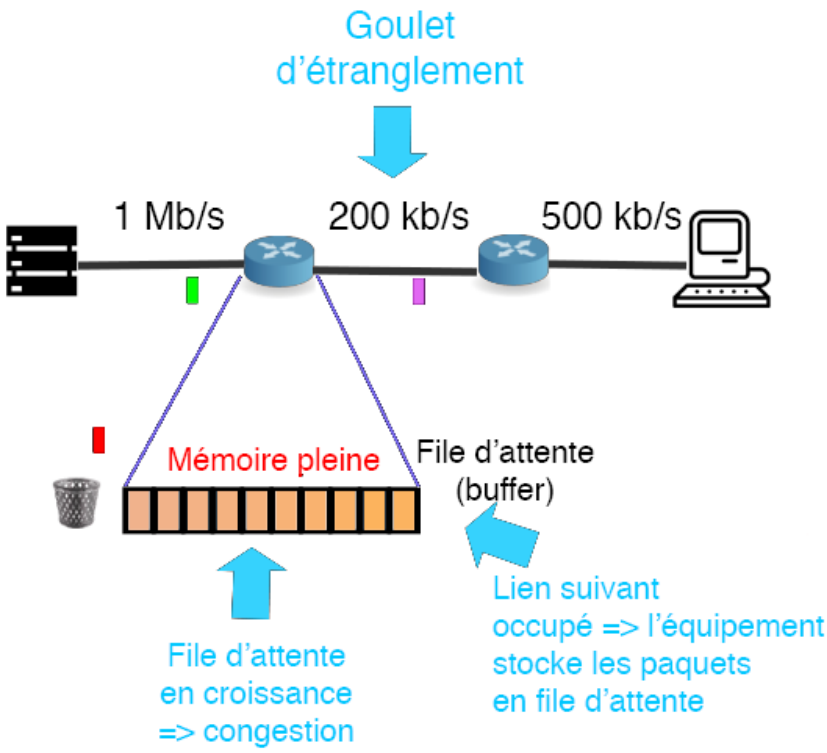

Un goulet d'étranglement situé au niveau du récepteur correspond au cas où la carte réseau de ce récepteur est soumise à un trafic plus important qu'elle ne peut gérer. Dans ce cas, la mémoire tampon dédiée à la réception des trames va rapidement être saturée, conduisant à des pertes. Pour régler ce problème, TCP impose aux correspondants d'inclure, dans l'en-tête des segments et des acquittements, la valeur de l'espace mémoire dont ils disposent. TCP utilisera alors ce seuil comme une limite absolue du volume de données qu'il est capable de transmettre.

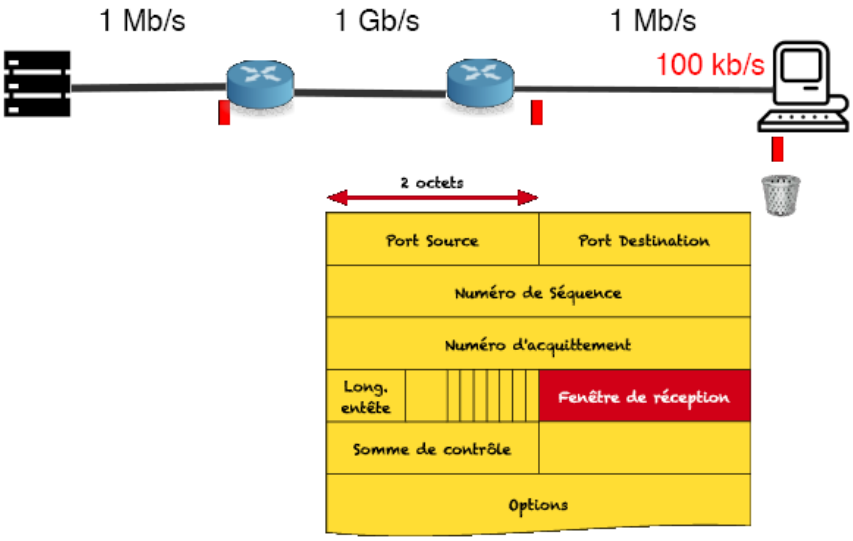

Lorsque le goulet d'étranglement est situé au sein du réseau, le problème est plus complexe. En effet, collecter une valeur analogue à la fenêtre de réception pour chacun des équipements intermédiaires serait très coûteux en volume de trafic. En outre, cette stratégie serait inutile puisque les conditions du réseau varient très rapidement. C'est pourquoi TCP ne se base pas sur une évaluation précise de l'état des équipements intermédiaires, mais préfère examiner le rythme de réception des acquittements pour en tirer des conclusions sur l'état de congestion du réseau.

TCP va donc évaluer en permanence la performance que le réseau peut lui fournir. L'échange initial d'ouverture de connexion permettra d'avoir une première évaluation du délai d'aller-retour. TCP va ensuite s'autoriser à envoyer 2 segments avant de s'arrêter pour attendre les deux acquittements correspondants. Si tout s'est bien passé, TCP s'autorisera à envoyer 4 segments avant d'attendre, puis 8 segments, puis 16 segments, etc, et ce, jusqu'à atteindre la valeur de la fenêtre de réception qui lui a été communiquée par son correspondant. Le volume total de données que TCP s'autorise à envoyer dans le réseau avant d'attendre les acquittements se nomme fenêtre de congestion. La taille de cette fenêtre de congestion, avec cet algorithme, augmente exponentiellement : elle est multipliée par 2 à chaque délai d'aller-retour. Cet algorithme se nomme démarrage lent ou *slow start*.

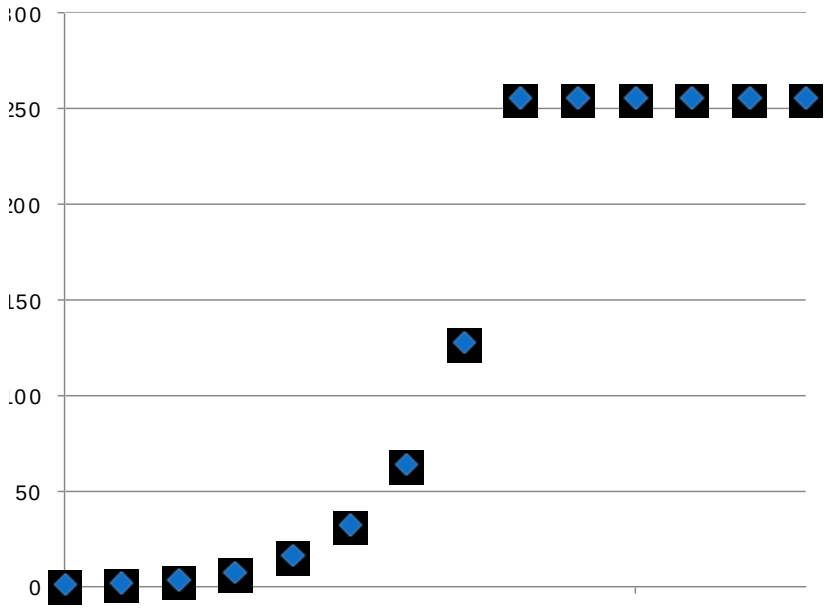

Lorsque TCP constate la perte d'un segment, c'est-à-dire que l'acquittement correspondant n'arrive pas dans le délai imparti, il va réduire brutalement le débit d'émission de la source en réinitialisant le débit de la fenêtre de congestion à sa valeur initiale. La philosophie, derrière cette réduction brutale, est qu'une congestion est due à un grand nombre de flux qui émettent à un débit trop important. Le réseau traitant *a priori* équitablement tous les flux, tous les flux incriminés vont subir une perte et vont, par conséquent, s'ils jouent le jeu, réduire leur débit, conduisant à une résolution rapide de la congestion.

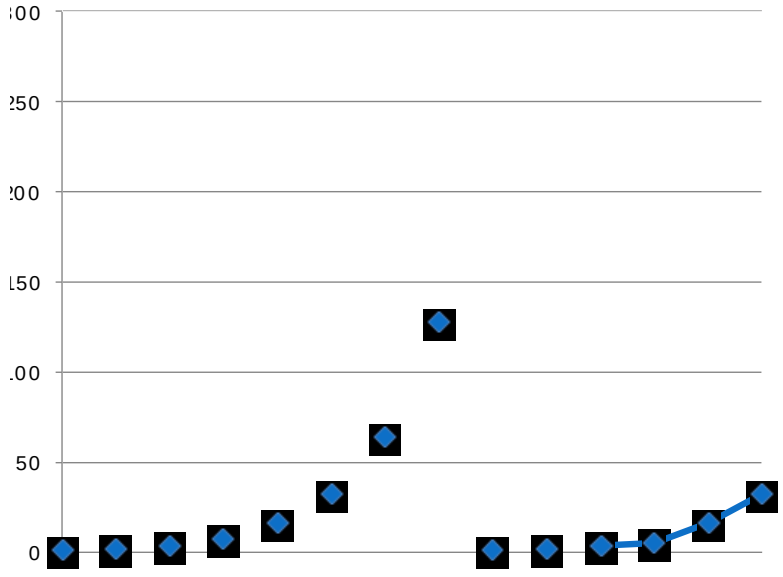

Le mécanisme du démarrage lent n'est pas très fluide. En effet, il conduit à une augmentation de plus en plus rapide du débit jusqu'à atteindre un point de saturation dont la détection provoquera un freinage brutal. Le débit réaugmentera ensuite de plus en plus rapidement jusqu'à un nouveau point de saturation et ainsi de suite. Par conséquent, le réseau, aussi bien que les sources, voient des oscillations dans leur débit.

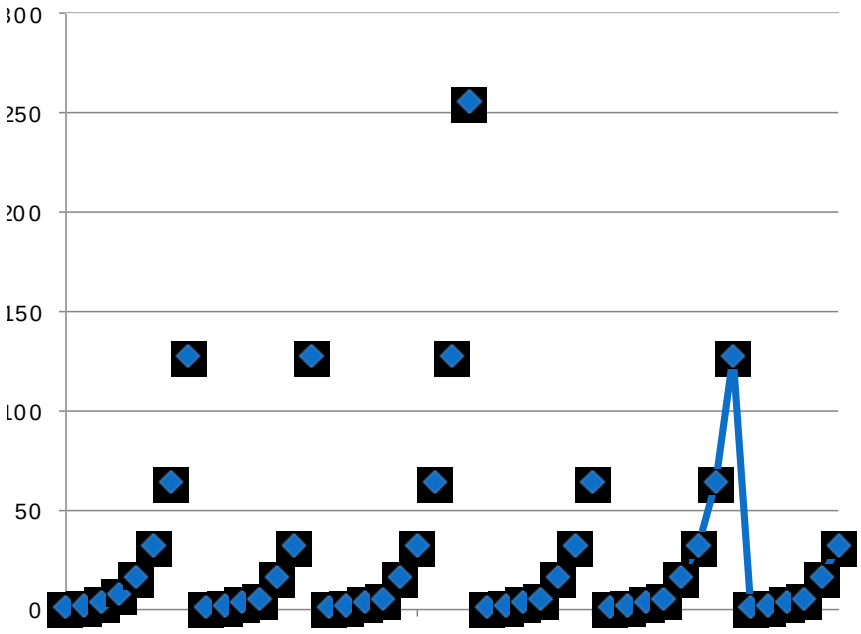

C'est pour éviter ces oscillations que TCP introduit un seuil au delà duquel l'augmentation de la fenêtre de congestion n'est plus exponentielle mais linéaire. Ce seuil s'appelle « seuil d'évitement de congestion ». Une fois que la fenêtre de congestion a atteint cette valeur, elle n'augmente plus que d'une unité à chaque fois que l'on a reçu l'intégralité des acquittements d'une rafale. Lors d'une perte, la valeur de la fenêtre de congestion est réinitialisée à 1 et la valeur de ce seuil est divisée par 2.

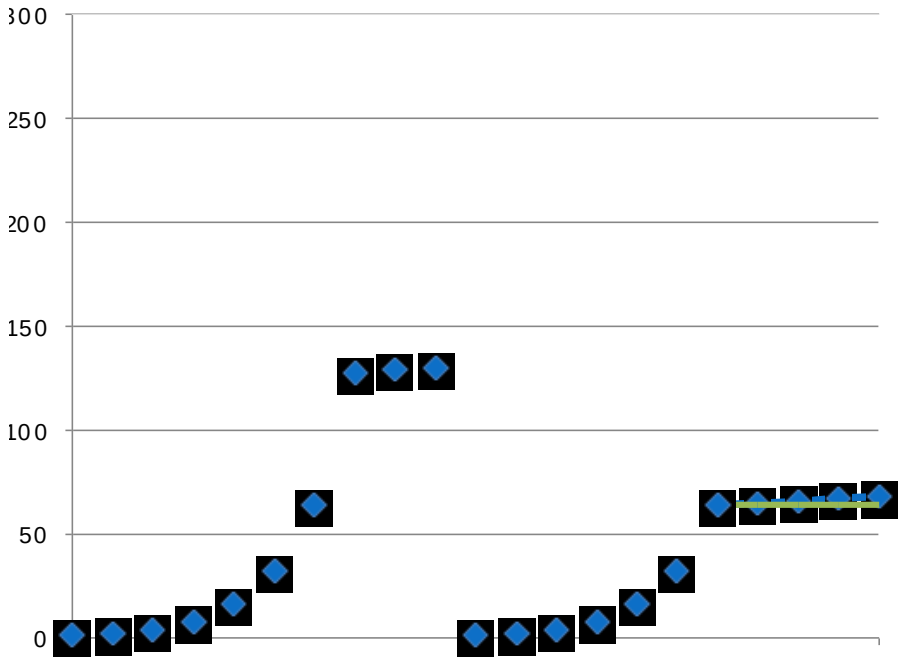

Ces algorithmes sont efficaces dans le cas d'une congestion sévère conduisant à la perte d'une rafale de segment. Cependant, dans le cas d'une congestion éphémère ou modérée conduisant à la perte d'un segment, par exemple, la réinitialisation de la fenêtre de congestion à une valeur de 1 est trop brutale. C'est pourquoi TCP ajoute d'autres mécanismes qui sont spécialement dédiées à la gestion des collisions de faible importance.

L'ensemble des algorithmes que nous avons vus ici constitue la base du contrôle de congestion de TCP. De nombreuses versions de TCP existent et coexistent dans l'Internet d'aujourd'hui. Il faut réaliser ici que TCP ne met en jeu que les terminaux et que, par conséquent, il est relativement aisé de développer, déployer et tester une nouvelle version de TCP puisque cela n'implique pas de mettre à jour les équipements réseau.

Les applications qui utilisent TCP sont des applications dites élastiques. Elles n'ont pas, *a priori*, de contrainte de temps, hormis la volonté que la transmission soit la plus rapide possible. Elles peuvent tolérer une variation dans la performance du réseau et leur flux va s'étirer et se contracter au gré des variations de disponibilité des ressources. Ce mode de fonctionnement ne convient pas, par contre, à des applications multimédia pour lesquelles des contraintes « temps réel » existent. C'est pourquoi ces applications utiliseront de préférence UDP.

Nous avons vu, dans cette séance, les bases du contrôle de congestion mis en œuvre par TCP. Ceci conclut notre présentation des protocoles de transport les plus utilisés dans les réseaux de données.