

Réseaux & Protocoles

Réseaux & Protocoles

Protocole TCP

Réseaux & Protocoles : TCP

TCP

- **TCP : Transmission Control Protocol**

Défini par la RFC 793⁽¹⁾

IP : Protocole non fiable $\Rightarrow$ "Best effort protocol"

TCP est indépendant de la couche IP

TCP gère la fiabilité des échanges

⁽¹⁾ RFC 793 (1981) $\rightarrow$ Nombreuses adaptations
RFC 7474 $\rightarrow$ Synthèse des modifications apportées à la RFC 793

Réseaux & Protocoles : TCP

Objectifs initiaux⁽¹⁾

- Définir un protocole de communication caractérisé par
 - Fonctionnement au dessus de la couche IP
 - Gestion d'un circuit logique fiable et sécurisé entre processus
 - Transmission d'un flux de données bidirectionnelles
 - Gestion de la fiabilité des données
 - Contrôle de flux
 - Accepte les connexions multiples

⁽¹⁾ Cerf & Kahn "A protocol for packet network intercommunication" Mai 1974

Propriétés de TCP

- Protocole orienté connexion
 - Établissement d'un chemin virtuel entre source et destination
 - Chemin virtuel indépendant de la couche IP
 - Mécanisme d'identification du chemin virtuel
 - Acheminement sans erreur des données
 - Données délivrées dans l'ordre d'émission
 - Communication full-duplex

Gestion de congestion

Optimisation de l'efficacité réseau

Interface TCP

- Paquet TCP = (En-tête + données) transmises par la couche TCP

TCP propose une interface permettant :

Ouvrir / Fermer une connexion

Émettre / Recevoir des données

Obtenir le statut d'une connexion

TCP utilise des buffers pour échanger les données avec les couches adjacentes

Réseaux & Protocoles : TCP

Interface TCP

- Interface utilisateur fournie par TCP
 - `open (port, foreign socket, mode
 [, timeout] [, précedence] [, security] [, options]
) → con_name`
 - `send (con_name, buffer, byte_count, push, urgent [,
 timeout])`
 - `receive (con_name, buffer, byte_count
) → byte_count, urgent, push`
 - `close ( con_name )`
 - `status ( con_name )`
 - `abort ( con_name )`

Réseaux & Protocoles : TCP

En-tête TCP

0	4	8	16	31
Source port			Destination port	
Sequence Number				
Acknowledgement Number				
Data Offset	Flags		Window	
Checksum			Urgent Pointer	
Options				
Data				
...				

Réseaux & Protocoles : TCP

En-tête TCP

- Port source Port hôte émetteur
- Port destination Port récepteur

Gestion des ports idem UDP
Port associé à un service

TCP retransmets les paquets dans la pile FIFO du service destination

- Intégrité $\Rightarrow$ Tous les paquets transmis sont valides
- Respect des flux $\Rightarrow$ Les paquets sont transmis dans l'ordre

En-tête TCP

- Sequence Number
- Acknowledgement Number

Identifiants permettant de gérer la connexion

- Identifie la connexion en cours
- Indication de flux
- Validation des paquets reçus

Réseaux & Protocoles : TCP

En-tête TCP

- Data offset Dimension du champ option
Indique la position des données

Valeur = Position du 1^{er} octet de données / 1^{er} octet en-tête
1 ligne = 4 octets
Bourrage si taille $\neq$ options Modulo 4

- Pas d'option $\Rightarrow$ Data Offset = 5

Valeur maxi codée sur 4 bits $\Rightarrow$ Data offset maxi = 15
 $\Rightarrow$ 40 octets d'options au maximum

Réseaux & Protocoles : TCP

En-tête TCP

- Drapeaux⁽¹⁾
 - CWR Congestion Window Reduced
 - ECE Explicit Congestion Notification Echo
 - URG Signale un traitement urgent
 - ACK Message d'acquittement
 - PSH Activation de la fonction push
 - RST Demande de Reset
 - SYN Message de synchronisation de connexion
 - FIN Fin de la connexion

⁽¹⁾ Champ drapeaux codé sur 12 bits. Les bits de poids fort sont positionnés à 0
La signification de chacun sera présentée ultérieurement.

En-tête TCP

- Window Fenêtre de réception

⇒ Indique à l'émetteur la quantité de données qui peuvent être transmises $\Leftrightarrow$ Espace disponible dans le buffer de réception.

- La valeur est significative si le drapeau ACK est positionné

Remarque : Les mécanismes liés à la charge du réseau seront présentés ultérieurement

En-tête TCP

- Checksum Validation du paquet⁽¹⁾
→ en-tête TCP + Données + pseudo-en-tête IP
- Urgent Pointer Position des données dont le traitement est prioritaire
⇒ Si drapeau URG est positionné

⁽¹⁾ Contrairement à UDP, checksum est obligatoire à l'émission, et doit être validé à la réception

Réseaux & Protocoles : TCP

Pseudo en-tête IPv4

0	8	16	31
Adresse source			
Adresse destination			
Zero	Protocole	TCP Length	

- Protocole TCP $\Rightarrow$ 6


Pseudo en-tête IPv4 identique pour UDP et TCP

Principes de base

Réseaux & Protocoles : TCP

Établissement de la connexion

- Poignée de mains à 3 voies⁽¹⁾




⁽¹⁾ Three-way handshaking

Réseaux & Protocoles : TCP

Établissement de la connexion

- Poignée de mains à 3 voies⁽¹⁾




(1) Three-way handshaking

Réseaux & Protocoles : TCP

Établissement de la connexion

- Poignée de mains à 3 voies⁽¹⁾



(1) Three-way handshaking

Gestion des connexions

- TCP gère les connexions en full-duplex
- Chaque sens de communication est indépendant
 - NSEQ = N° séquence $\Rightarrow$ Donnée émises
NSEQ = position du 1^{er} octet de données dans le flux
 - NACK = N° acquittement $\Rightarrow$ Données reçues
NACK = Position du prochain octet attendu dans le flux

Gestion des connexions

- TCP peut gérer des flux séparés
- Un flux est identifié par le couple (@IP , port) ⁽¹⁾

Remarque :

Processus répertoriés par IANA

⇒ Établissement de la connexion sur le port dédié

Service reçoit requête sur port dédié

En retour, TCP spécifie le n° de port pour les échanges suivants

⁽¹⁾ Enregistrement des flux dans la structure TCB

TCB : Transmission Control Block

- Structure de gestion des connexions établies contenant :
 - ♦ Identification du processus utilisant la connexion
 - ♦ Pointeurs sur les buffers / fenêtre
 - ♦ Timers de connexion
 - ♦ Indicateurs de statut
- TCP utilise une table de structures TCB

! A chaque requête SYN, une entrée TCB est définie
⇒ Waiting TCB Connexion en cours d'établissement

Remarque : La structure des TCB est décrite dans RFC 675

SYN Flood Attack

- **Attaque de type DOS par saturation des TCB**
- Rappel : Une connexion TCP est établie par un protocole de Handshake en 3 temps
 - 1) Demande d'ouverture de connexion par le client → SYN
 - 2) Réponse du serveur → SYN / ACK
Une entrée TCB est réservée dans le backlog SYN
 - 3) Validation par le client → SYN / ACK
L'entrée TCB du backlog est supprimée → Transfert vers gestion des connexion établie

SYN Flood Attack

- Attaque de type DOS par saturation des TCB
 - 1) Demande d'ouverture de connexion par le client → SYN
 - 2) Réponse du serveur → SYN / ACK
Réservation entrée TCB
 - 3) !! Pas de validation par le client
L'entrée TCB du backlog reste en attente jusqu'au timeout
 - 4) Le client boucle en 1) pour multiplier les entrées
 - 5) Le serveur est saturée lorsque l'espace mémoire alloué au TCB backlog est plein

SYN Flood Attack

- Prévention des attaques de type SYN Flooding
- Augmenter la taille mémoire allouée au backlog
⇒ Nb requêtes maxi $\text{dim. mémoire} / \text{timeout}$ ¹
- Si requêtes émises par le même client (@IP, ...)
⇒ Blocage de l'@IP ²
- Recycler les connexions TCP semi-ouvertes les plus anciennes
- Lorsque le backlog est plein, les entrées TCB ne sont pas conservées mais les ports restent ouverts. Si une réponse valide est reçue (validation par pare-feu), alors reconstruction (partielle?) de l'entrée TCB

¹ Le trafic attaque SYN Flood < trafic attaque DDoS usuelles

² Protection inefficace contre les botnets

Numéro de séquence

- Établissement de la connexion

Valeur pseudo-aléatoire non prédictive codée sur 32 bits

RFC 793 → Le choix de ISN n'est pas arbitraire
→ Générateur 32 bits, incrémenté chaque 4μs
→ Délai de $2 * \text{MSL}$ entre 2 connexions
MSL = Maximum Segment Lifetime


⇒ Un attaquant peut prédire le numéro de séquence

RFC 6528 - Defending against sequence number attacks

Réseaux & Protocoles : TCP


Envoi de données

1) Envoi de 10 octets



Réseaux & Protocoles : TCP

Envoi de données



Communication fiable

- TCP assure la validité des données et leur remise dans l'ordre
⇒ Gestion réalisée par les numéro de séquence et d'acquittement
- Émetteur envoie de données → N° séquence identifie 1^{er} octet
Émetteur enregistre les données émises dans un buffer
+ déclenche un timer
- Récepteur envoie un acquittement
n° acquittement = n° séquence + taille des données
⇒ n° acquittement = position du prochain octet attendu
- Après acquittement, émetteur supprime les données de son buffer


Numéro d'acquittement

- Le numéro de séquence permet d'identifier chaque données émise
Chaque donnée peut donc être validée par le récepteur
- Mécanisme d'acquittement cumulatif
⇒ Acquittement valide toutes les données précédentes
- Numéro de séquence défini sur 32 bits ⇒ Utiliser modulo 2^{32}
- Règle de gestion de nseq et nack
 - ♦ nack doit correspondre à une valeur nseq non encore validée
 - ♦ Les données à émettre ne sont retirées du buffer qu'après validation
 - ♦ nseq du segment reçu doit correspondre aux données attendues

Réseaux & Protocoles : TCP

Fermeture de la connexion

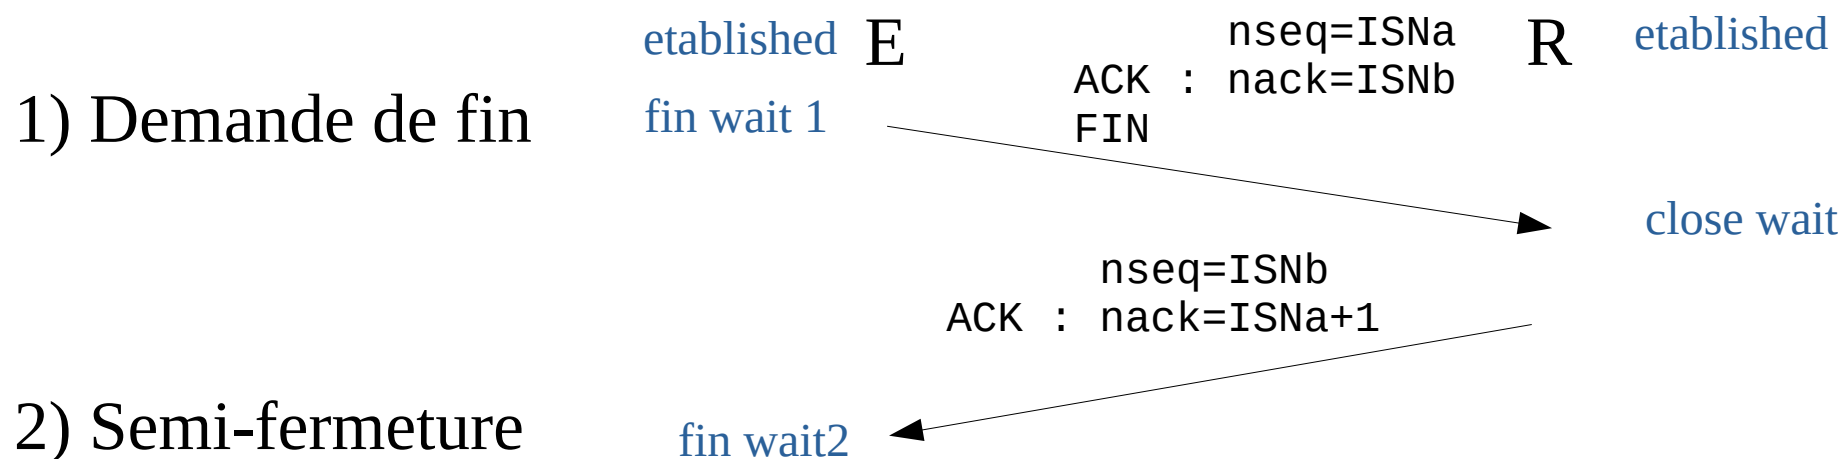
- Fermeture normale de la connexion



Réseaux & Protocoles : TCP

Fermeture de la connexion


- Fermeture normale de la connexion



Réseaux & Protocoles : TCP

Fermeture de la connexion


- Fermeture normale de la connexion



Réseaux & Protocoles : TCP

Fermeture de la connexion

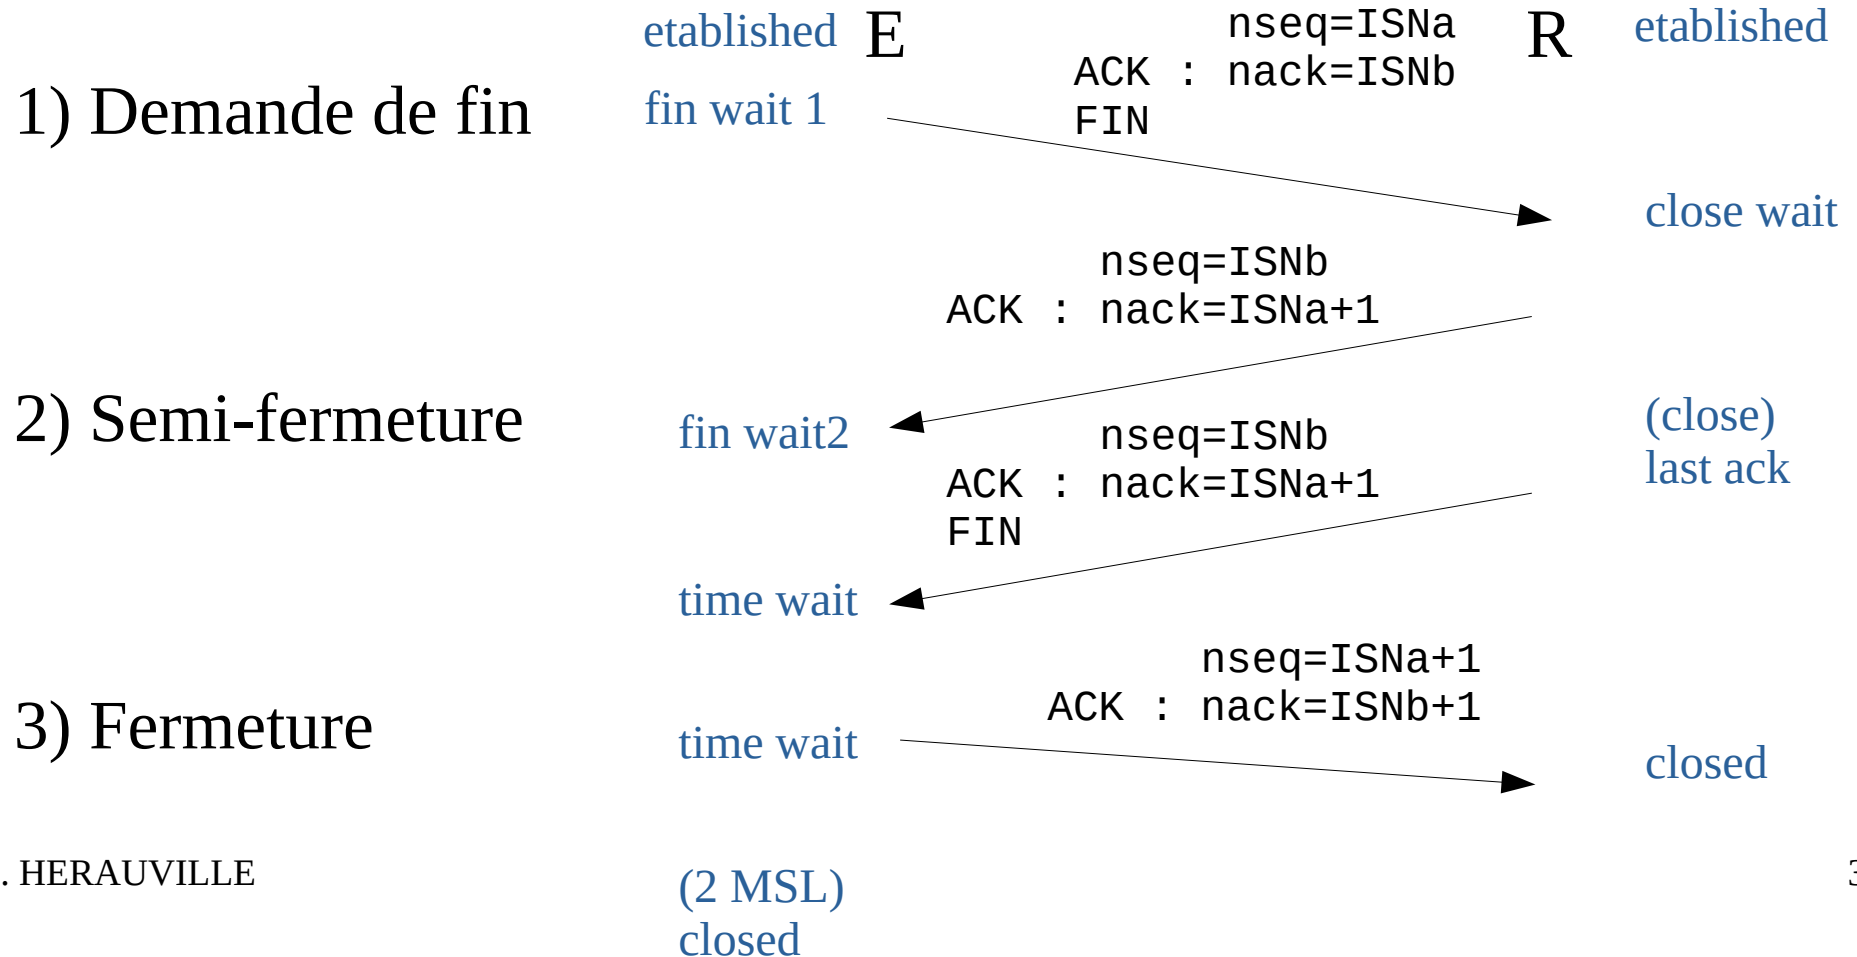
- Fermeture normale de la connexion



Réseaux & Protocoles : TCP

Fermeture de la connexion

- Fermeture normale de la connexion



Quiet Time concept

- Après fermeture de connexion
ISN >> dernière valeur nseq Pour éviter confusion
Recommandation RFC Incréments chaque $4\mu s^{(1)}$
- MSL = Maximum Segment Lifetime
⇒ Durée de vie normale d'un segment < 10s (selon débit)
Temps attente obligatoire après crash système
- Quiet Time ⇒ Attente minimale pour éviter confusion nseq
⇒ MSL = 2mn par défaut

⁽¹⁾ 2^{32} bits ⇒ Durée cycle environ 4,55 heures


Half-duplex

- La fermeture de connexion est uni-directionnelle
Si fermeture → R ne souhaite plus recevoir de données
- Fermeture Half-Duplex
 - ♦ La connexion reste établie
 - ♦ La transmission de données est unidirectionnelle
 - ♦ Les signaux de validations restent bi-directionnels
- Fermeture Full-Duplex
 - ♦ Fin de la connexion

Réseaux & Protocoles : TCP

Reset de la connexion

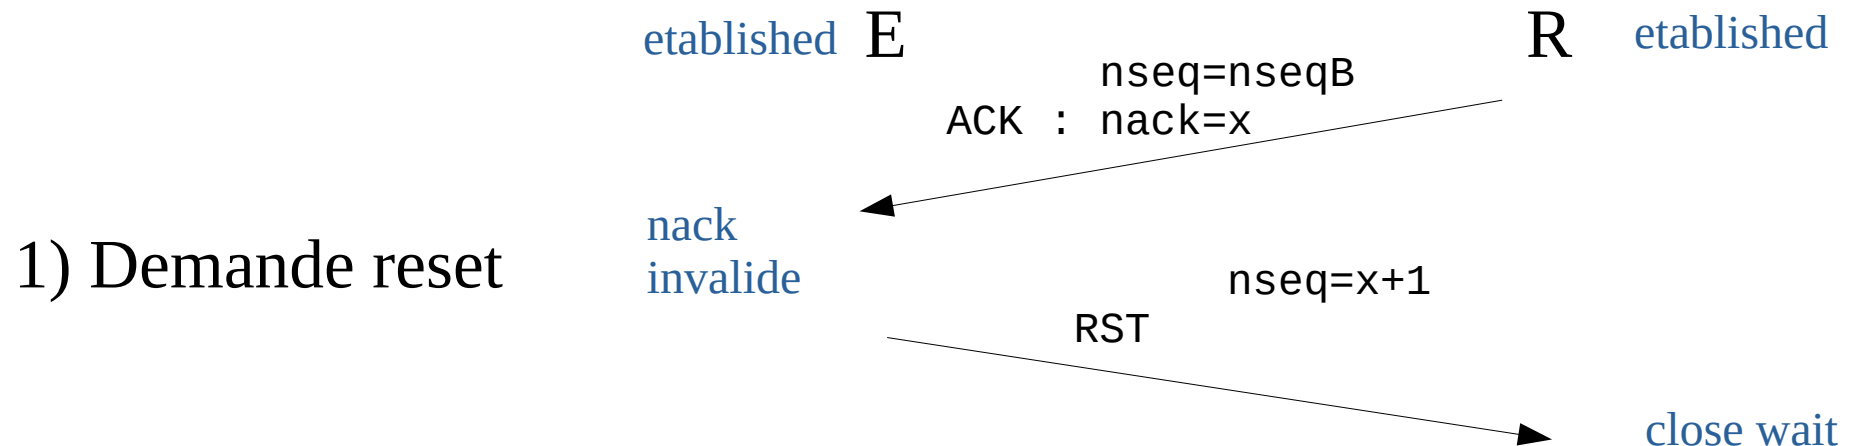
- Reset si détection d'anomalie



Réseaux & Protocoles : TCP

Reset de la connexion

- Reset si détection d'anomalie



Reset

- Demande de fermeture immédiate de la connexion
- Si la connexion établie (sauf état SYN-SENT)
 - Reset est valide si
 - ♦ nseq compris dans la fenêtre normale de connexion
- État SYN-SENT → demande de connexion en cours
 - Reset valide si
 - ♦ ACK acquitte message SYN

Blind Attack

- Une connexion TCP est identifiée par 5 informations :
Protocole, Adresses source et destination, Ports source et destination
- Possibilité de créer une attaque (en aveugle¹) si l'attaquant est en mesure de générer ces tuples avec une probabilité élevée.
⇒ Génération d'un message ICMP comportant les identifiants TCP pour engendrer un reset de la connexion ⇒ Deni de service
- Contre-mesures :
 - Générateur aléatoire pour sélectionner le numéro de port
 - Filtrage des message ICMP : Ne traiter que ceux associés aux messages en cours (non acquitté)

(¹) Attaque en aveugle : Les données ne sont pas connues mais un nombre limité de tentatives permet de les créer (Exemple : Séquence aléatoire prévisible)

Références : rfc5927, rfc6056, http://www.gbppr.net/2600/SlippingInTheWindow_v1.0.pdf

Gestion des fenêtres

Fenêtres TCP

- Synchronisation des échanges gérée par l'utilisation de fenêtres glissantes¹
- Fenêtre d'émission
Buffer des données disponibles pour l'émission
- Fenêtre de réception
Buffer de données disponible pour la réception
- n° seq & n° ack ⇒ Indicateur de position / buffer


¹ Fenêtre glissante : Sa position de référence se déplace

TCB : Transmission Control Block

- Send Sequence Variables
 - `SND.UNA` Send unacknowledged
 - `SND.NXT` Send next
 - `SND.WND` Send window
 - `SND.UP` Send urgent pointer
 - `SND.WL1` Segment sequence number use for last window update
 - `SND.WL2` Segment acknowledgement number use for last window update
 - `ISS` Initial send sequence number

Réseaux & Protocoles : TCP

Fenêtre d'émission




- ① - Données émises et acquittées
- ② - Données émises, non acquittées
- ③ - Données prêtes, non encore émises
- ④ - Données non prêtes $\Leftarrow$ Fournies par application

TCB : Transmission Control Block

- Receive Sequence Variables
 - RCV.NXT Receive next
 - RCV.WND Receive window
 - RCV.UP Receive urgent pointer
 - IRS Initial receive sequence number

Réseaux & Protocoles : TCP

Fenêtre de réception




- ① - Données reçues et acquittées
- ② - Zone de données prête à la réception
- ③ - Zone non prête, pour futures données

TCB : Transmission Control Block

- Current Segment Variables
 - SEQ . SEQ Segment sequence number
 - SEQ . ACK Segment acknowledge number
 - SEQ . LEN Segment length : Dimension des données dans le segment
 - SEQ . WND Segment window
 - SEQ . UP Segment urgent pointer
 - SEQ . PRC Segment precedence value


Réseaux & Protocoles : TCP

Statut de la connexion - Ouverture



Réseaux & Protocoles : TCP

Statut de la connexion - Fermeture



Validation des données


Validation des données

- TCP propose des mécanismes pour valider les données
nseq / nack $\Rightarrow$ Acquittement des données reçues & valides
- ♦ R $\rightarrow$ Détection de données non reçue
- ♦ E $\rightarrow$ Données non acquittées

Réseaux & Protocoles : TCP

R → Données non reçues


- Chaque segment possède un numéro de séquence
⇒ Position des données



Réseaux & Protocoles : TCP


R → Données non reçues

- Chaque segment possède un numéro de séquence
⇒ Position des données




Réseaux & Protocoles : TCP

R → Données non reçues



Réseaux & Protocoles : TCP

R → Données non reçues




E → Time out

- Détection d'un segment non arrivé à destination
E ne reçoit pas de message d'acquittement
- Causes possibles de la non réception d'un message :
 - ♦ Délai acheminement trop long (routage, congestion)
 - ♦ Message perdu (congestion, défaillance, ...)
 - ♦ Message incorrect (CRC non valide,...)
- Règles TCP : Un segment est considéré perdu si non acquitté :
 - a) Après durée au moins égale à Time Out
 - b) Après 3 nack identiques

Réseaux & Protocoles : TCP

E → Time out (a)



Réseaux & Protocoles : TCP

E → Time out (a)

- ACK non reçu après Time Out
⇒ Le segment est re-transmis automatiquement
- RTT Round Trip Time ⁽¹⁾
- RTO Retransmission Time Out ⁽²⁾

⁽¹⁾ Ré-évaluation régulière (voir plus loin)

⁽²⁾ Calcul RTO présenté plus loin

Réseaux & Protocoles : TCP

E / R → ACK regroupé

- R ne doit pas émettre un ACK pour chaque segment
- E peut envoyer plusieurs segments


⇒ Optimisation du trafic réseau

Évite surcharge réseau due aux messages d'acquittement
Optimise le débit

- Règles TCP ⇒ ACK doit être envoyé :
 - ♦ Délai < Time Out ⇒ 100 ... 200 ms
 - ♦ ACK immédiat si détection de segment manquant
 - ♦ ACK immédiat pour chaque second segment reçu

Réseaux & Protocoles : TCP

ACK regroupés (1)




⇒ Fonctionnement normal sans anomalie

- Permet d'augmenter le débit
- Limite la charge réseau / message acquittement


Réseaux & Protocoles : TCP

ACK regroupés (2)




Réseaux & Protocoles : TCP

ACK regroupés (2)




Réseaux & Protocoles : TCP

ACK regroupés (2)



Réseaux & Protocoles : TCP

ACK regroupés (2)



Calcul du Time Out

- RTT Mesuré à intervalle régulier
⇒ Estimation du réseau → Adaptation TCP
- Mesure de RTT par Estampille ⁽¹⁾
- RTO Défini par RFC 6298

⁽¹⁾ Voir options TCP

Calcul du Time Out

- Valeurs initiales
 - ♦ $RTT = 0$
 - ♦ $RTO = 1s$
- Tentative de connexion
 - 1) Envoyer demande de connexion
 - 2) Si ACK non reçu $\Rightarrow RTO = RTO \times 2 \Rightarrow$ reprendre en 1)
- $RTO_{max} = 64s$

Si connexion non établie avec $RTO = RTO_{max}$ ⁽¹⁾
Fin de connexion $\Rightarrow$ Émission RST

⁽¹⁾ Délai maxi $< 9mn$ si aucune réponse

Calcul du Time Out

- **Valeurs initiales** $RTT = 0$ $RTO = 1s$
- **Après 1ère mesure** $RTT \rightarrow mRTT$
 - $SRTT = mRTT$
 - $RTTVAR = mRTT / 2$
 - $RTO = SRTT + \max(G, K * RTTVAR)$
- $mRTT$ Dernière valeur mesurée pour RTT
- $SRTT$ Valeur de RTT moyennée
- $RTTVAR$ Variations entre les mesures de RTT
- G Granularité de l'horloge $G_{optimum} \leq 100ms$
- K Constante $K = 4$

Calcul du Time Out

- **Mesures suivantes**

- $RTTVAR = (1-\beta) * RTTVAR + \beta * |SRTT - mRTT|$
- $SRTT = (1-\alpha) * SRTT + \alpha * mRTT$
- $RTO = SRTT + \max(G, K * RTTVAR)$

- α Constante $\alpha = 1/8$
- β Constante $\beta = 1/4$

- **Limites RTO**

$$1s < RTO < 60s$$

Si expiration RTO $\Rightarrow$ RTO min = 3s

Réinitialiser le calcul de RTO

Calcul du Time Out

- Algorithme de Karn ⁽¹⁾
Analyse pour optimiser la valeur de RTO
 - Mesure de RTT
→ Délai entre émission segment et réception ACK
- 1) Un segment retransmis ne peut servir pour la mesure de RTT
 - 2) Ne pas effectuer de mesures de RTT en parallèle
 - 3) Si mesure de RTT incorrecte, conserver les valeurs courantes
 - 4) Maintenir $RTO \gg RTT$

⁽¹⁾ Improving RTT Estimates in Reliable Transport Protocols - 1987

Delayed ACKs

- TCP permet de regrouper les messages ACK
 - Pour optimisation, R peut regrouper les messages ACK
 - ! ACK doit être transmis avant RTO
 - ! R ne sait par avance quand un segment va arriver
- ⇒ R envoie ACK avec un délai maximal $RTO_{min} / 2 = 500ms$
- ACK valide le dernier segment reçu correctement

Réseaux & Protocoles : TCP

Algorithme de Naggle ⁽¹⁾

- Optimisation de l'efficience réseau
- Remarque : Émission TCP d'un segment avec 1 octet de données
En-tête TCP = 20 octets minimum
En-tête IP = 20 octets minimum
Efficacité réseau = $1 / 41 = 2,4 \%$

Exemple : Telnet $\Rightarrow$ Envoi immédiat de chaque caractères

⁽¹⁾ RFC 895 (1984) updated by RFC 7805

Algorithme de Naggle

- Émission immédiate du premier octet
 - Accumulation des octets suivants dans buffer jusqu'à :
 - a) Buffer plein
 - b) Acquiescement du message précédent
- ⇒ Le message suivant comprendra l'intégralité du buffer
- Option TCP_NODELAY ⇒ Permet de désactiver l'algo de Naggle

Algorithme de Naggle

- Problème : Delayed ACKs
- R envoi ACK après délai variable (100...200 ms)
 - ⇒ Delayed ACK génère une latence au niveau de l'application
- TCP ne peut optimiser cette latence
 - ⇒ Désactiver algorithme de Naggle ou Interdire delayed ACKs ?


Algorithme de Naggle

- Incidence des ACK regroupés sur l'algorithme de Naggle
R émet un ACK si :
 - a) Second segment reçu
 - b) Expiration du délai depuis dernier segment non acquitté
- Proposition de modification
E peut émettre un segment si
 - ♦ Aucune données fournie par l'application n'est en attente
 - ♦ 1 seul segment n'a pas été acquitté


Réseaux & Protocoles : TCP

Algorithme de Naggle

- Illustration de l'incidence de l'algorithme de Naggle



Transmission / 100 000 octets



Transmission / 99 913 octets

Explication :

100 000 octets Le découpage engendre un nombre de segments impair
⇒ ACK immédiat pour les segments pairs (cas de 99 913 octets!)

Rque : Windows → TCP segment size = 1460 o / Mac OS X → TCP segment size = 1448 o

Flag PUSH

- Demande la transmission "immédiate" des données
 - E → Transmet le contenu du buffer
 - R → Fourni le contenu du buffer de réception à l'application
- Objectif : Éviter une latence au niveau applicatif ¹

Remarque : L'application est censée positionner le flag PUSH lors de l'émission de son dernier segment.

¹ Force l'envoi immédiat de données de petites dimensions

Flag URGENT

- Indication de données urgentes
⇒ incite R à commuter en mode urgent
- Flag URG ⇒ Spécifie que URG. PTR est significatif
- URGENT POINTER ⇒ Position des données urgentes ¹
Position des données urgentes indiquées par $\text{nseq} + \text{urgent pointer}$

¹ *L'action associée aux données urgentes est gérée par l'application.*

Options

Options

- Champ option complété par du bourrage si nécessaire
- Format d'une option type [taille] [contenu]
 - Type 1 octet Identifiant de l'option
 - Taille 1 octet Nombre d'octets utilisés par l'option
(Si l'option utilise un contenu)
- TCP doit ignorer les options non implémentées,
sans générer d'erreur

Options limitées à 1 octet

- Type = 0 Indicateur de fin de la liste des options
Utilisé si le dernier octet d'option n'est pas aligné
Ne doit pas être utilisé entre 2 options
- Type = 1 No-operation
Peut être utilisé entre 2 options (pour alignement)
! Alignement des options non imposé par la norme

Réseaux & Protocoles : TCP

Maximum segment size ⁽¹⁾

- Type = 2
Taille = 4
Data = Max Segment Size

Si cette option est présente

Indique la dimension maximale des données pouvant être traitées

Valeur par défaut = 536 → 576 - 40

MSS doit être transmis à la création de la connexion ⁽²⁾

⁽¹⁾ RFC 6691

⁽²⁾ MSS ne peut être supérieur à la valeur de MTU du réseau de l'hôte

Réseaux & Protocoles : TCP

Maximum segment size

- $\text{Eff.snd.MSS} = \min(\text{SendMSS} + 20, \text{MMS_S})$
- TCPHdrsize - IPOptionsize
- SendMSS Valeur transmise par hôte distant (536 par défaut)
- MMS_S Valeur max. acceptée par la couche transport⁽¹⁾
- TCPHdrsize Dimension en-tête TCP (>20 si options)
- IPOptionsize Dimension de toute option IP qui peut transiter par la couche TCP

*Remarque : La valeur MSS émise utilise des en-têtes sans option
⇒ L'émetteur doit ôter les options utilisées*

RTTM : Round-Trip Measurement

- Type = 8
Taille = 10
Data = Timestamp Value (4 octets)
Timestamp Echo Reply (4 octets)
- Timestamp Echo Reply valide uniquement si ACK
- Delayed ACK ne doit pas être activé si RTTM inclus dans le segment

Remarque : RTTM non valide si segment retransmis

TCP Window Scale Option ⁽¹⁾

- Le champ Window défini dans l'en-tête est limité à 32 bits
- Window Scale Option permet de définir un multiplicateur pour la valeur du champ Window
 - ⇒ Option valide uniquement si 2 hôtes ont transmis l'option à la connexion (SYN)
- Type = 3
 - Taille = 3
 - Data = shift count

Remarque : shift count = 0

⇒ Autorise émetteur à utiliser option

⇒ Valeur transmise = 1

RFC 5681

Congestion avoidance

Taille des fenêtres

- Champ "Window" Taille de la fenêtre de réception
 - Valeur numérique non signée codée sur 16 bits
 - Dimension de fenêtre de réception définie par l'émetteur
- Permet de limiter la charge réseau aux données exploitables
- Fenêtre de réception = Fenêtre "glissante"
 - ⇒ Indique à l'émetteur la quantité maximale de données qui peuvent être transmises avant validation
 - ⇒ Valeur spécifiée / ACK transmis dans le même segment

Taille des fenêtres

- Restrictions
- La taille de fenêtre ne peut être diminuée sans validation
→ Acceptation de la nouvelle valeur par émetteur pour les données suivantes (restrict window)
- Tout poste TCP doit pouvoir accepter au moins 1 octet de données
- E doit transmettre un segment à intervalle régulier, même si la taille de la fenêtre de réception est égale à 0 → Période 2 mn
- R doit valider tout segment de données reçu avec nseq correspondant aux données attendues

TCP congestion control ⁽¹⁾

- TCP définit 4 algorithmes afin d'optimiser l'efficacité du réseau
 - ♦ Slow-start
 - ♦ Congestion avoidance
 - ♦ Fast retransmit
 - ♦ Fast recovery
- RFC 5681 ⇒ Définition des algorithmes

⁽¹⁾ RFC 5681

Définitions

- **SMSS** Sender Maximum Size Segment
- **RMSS** Receiver Maximum Segment Size
- **Full-Sized Segment** Segment avec SMSS octets de données
- **rwnd** Receiver Windows
- **cwnd** Congestion Window
- **IW** Initial Window. Valeur initiale de cwnd
- **LW** Loss Window. cwnd après détection de perte de données
- **RW** Restart Window. cwnd après inactivité
- **FLIGHT SIZE** Taille des données émises sans ACK
- **DUPLICATE ACKNOWLEDGEMENT**
 Valeur de ACK dupliquée

Algorithme Slow Start

- Objectif : Ne pas surcharger le réseau au démarrage

L'algorithme Slow-start s'applique :

- a) Au démarrage d'une connexion
- b) Après une période d'inactivité (Idle period ⁽¹⁾)
- c) Après Time Out

⇒ S'applique si $cwnd < ssthresh$

⁽¹⁾ Idle period = Pas de segment reçu pendant durée $> RTO$

Algorithme Slow Start

- cwnd E → Fenêtre de congestion
Volume des données pouvant être transmises avant ACK
- rwnd R → Fenêtre de réception
Volume des données pouvant être reçues
- sstresh Slow Start Treshold
Valeur initiale choisie arbitrairement
ssresh mini = segment size maxi (with options) ⇒ MSS
ssresh doit être modifiable pour s'adapter au réseau

Réseaux & Protocoles : TCP

Initial Window ⁽¹⁾

- Taille de la fenêtre de congestion au démarrage

$$IW \leq \min (4 * MSS, \max (2 * MSS, 4380)) \quad (2)$$

Remarque : 4380 octets = 3 paquets IP avec en-têtes minimales

$$MSS \leq 1095 \quad \Rightarrow \text{win} \leq 4 * MSS$$

$$1095 \leq MSS < 2190 \quad \Rightarrow \text{win} \leq 4380$$

$$2190 \leq MSS \quad \Rightarrow \text{win} \leq 2 * MSS$$

- Discussion dans RFC 3390 sur valeur optimale
 - Si bande passante élevée Augmenter IW
 - Si charge réseau élevée Diminuer IW

⁽¹⁾ RFC3390

⁽²⁾ Valeur recommandée

Algorithme Slow Start

- Tant que $cwnd < ssthresh$
Pour chaque ACK reçu
 $cwnd = cwnd + \min (N, SMSS)$
avec $N = \text{nb octets validés par le dernier ACK}$
- Fin algorithme slow-start si
 - $cwnd > ssthresh$
 - Congestion réseau détectée
- Rappel :
A tout instant $\rightarrow \text{Données émises max} = \min (cwnd, rwnd)$

Algorithme Congestion Avoidance

- Objectif : Ne pas surcharger le réseau
S'applique lorsque la communication est établie
- si $cwnd \geq ssthresh$
Pour chaque RTT
 $cwnd = cwnd + SMSS^{(1)}$

Si perte de segment

- Si détection de paquet perdu via RTO
et aucune retransmission n'a été effectuée

$sstresh = \max (FlightSize / 2, 2 * SMSS)$

$FlightSize$ = Taille des données émises et
non encore validées par ACK

$cwnd = LW$

LW = Loss Window = 1 full-sized segment (Taille maxi)

- ! Si une retransmission a déjà été effectuée
⇒ $sstresh$ reste inchangé

Fast Retransmit Algorithme → R

- Si R reçoit un segment dans le désordre (détection de segment manquant)
⇒ Envoi immédiat ACK pour indiquer le segment manquant
- A chaque réception de segment dans le désordre
⇒ Duplicate ACK
- Si Segment manquant reçu
=> ACK / dernier élément correctement reçu

Fast Retransmit Algorithme → E

- Si E reçoit des duplicate ACK
 - Si $\text{duplicate ACK} \leq 2 \Rightarrow$ E continue les émissions normalement
 - Si $\text{duplicate ACK} = 3$
 - $\text{ssthresh} = \max (\text{FlightSize} / 2, 2 * \text{SMSS})$
 - E réémet le segment manquant
 - $\text{cwnd} = \text{ssthresh} + 3 * \text{SMSS}$
 - Pour chaque duplicate ACK reçu (> 3)
 - $\text{cwnd} = \text{cwnd} + \text{SMSS}$

Fast Retransmit Algorithme → E Fast Recovery

- Si E reçoit $\text{ACK} > \text{duplicate ACK}$ $\Rightarrow$ Reprise normale
- E envoie 1 segment avec des données non déjà émises
 - ♦ A la réception de ACK du dernier segment émis
 - $\text{cwnd} = \text{ssthresh}$ $\Rightarrow$ Fast recovery

Fast Recovery

- Après rétablissement "normal" de la connexion
 - $ssthresh = \max (FlightSize / 2, 2 * SMSS)$


⇒ Évolution "douce" des valeurs
- Reprise de congestion avoidance
 - $cwnd = cwnd + SMSS$
 - $cwnd = \min (cwnd , rwnd)$

Slow Start / Idle Period

- Après Idle Period, E doit utiliser l'algorithme de Slow Start
 $\text{cwnd} = \text{RW}$
 avec $\text{RW} = \text{Restart window} = \min (\text{IW}, \text{cwnd})$

Réseaux & Protocoles : TCP

Exemple



Option SACK ⁽¹⁾

- Selective Acknowledgement Options
 - ⇒ Duplicate ACK spécifie le plus ancien segment non reçu
 - Pas d'indication sur les segments reçus ultérieurement
- SACK-permitted Transmis lors de la création de la connexion
- SACK Utilisée lors de la perte de segment

! SACK autorisé uniquement si SACK-permitted reçu lors de l'établissement de la connexion

⁽¹⁾ RFC 2018

Option SACK-permitted

- Type = 4 $\Rightarrow$ Indique que l'hôte peut utiliser l'option SACK
Taille = 2

Option SACK

- Type = 5
Taille = variables $\rightarrow$ Selon données transmises
Data = Left edge of 1st block
 Right edge of 1st block
 ...
 Left edge of nth block
 Right edge of nth block

Option SACK

- ACK Valeur du plus ancien segment manquant
 ⇒ Duplicate ACK
- Block Segments reçus
 - ♦ Left edge of block = nseq du bloc
 - ♦ Right edge of block = nseq du segment suivant non reçu

Remarque : SACK est souvent utilisé conjointement avec l'option Timestamp

Option SACK

- Ordre des blocs transmis
- Le premier bloc spécifié correspond à celui ayant déclenché le message ACK
 - ⇒ $ACK = nseq$ du plus ancien segment non reçu
 - Left edge of 1^{er} block = $nseq$ du dernier segment reçu
- Si réception d'un segment manquant
 - ⇒ Il est inséré dans le bloc adjacent

RFC 3168

Explicit Congestion Notification

Détection de la congestion

- Congestion détectée si suppression de paquets IP
 - RTO Émetteur
 - ACK Récepteur
- Ajouts de bits supplémentaires pour anticiper la congestion
 - TCP CWR : Congestion Window Reduced ⁽¹⁾
 ECE : ECN Echo
 - IP ECT : ECN Capable Transport
 CE : Congestion Experienced


⁽¹⁾ Les drapeaux CWR & ECE doivent être positionné lors de la création de connexion

Indication de congestion dans IP ⁽¹⁾

- Ajout des bits ECN pour indiquer la congestion
 - ♦ ECN doit être compatible avec mécanismes existants
 - ♦ Gestion de congestion exploitable uniquement si les échanges se poursuivent pendant la phase de congestion
 - ♦ En général, communication asynchrone (retour = ACK)
⇒ Les chemins aller et retours peuvent être distincts
 - ♦ Les routeurs sont plus efficaces pour traiter les informations comprises dans l'en-tête IP, plutôt que les options

Réseaux & Protocoles : TCP

Indication de congestion dans IP



- DSCP : Differentiated Services Codepoint
- ECT CE ⇒ noms RFC 2481 obsolètes → ECN bits

0	0	ECN non géré	
0	1	ECT(1)	} Indication → ECN capable
1	0	ECT(0)	
1	1	Indication de congestion (Modifié par routeur)	

Active Queue Management

- Active Queue Management ⁽¹⁾ permet d'anticiper la détection de congestion avant la suppression des paquets
Seuil de déclenchement ⁽²⁾ avant saturation de la queue de messages
 - Si le mécanisme CE est supporté
 - ⇒ Marquer les paquets avec CE au lieu de les supprimer
 - Notification de réduction du trafic demandé
 - Si le mécanisme CE n'est pas disponible
 - ⇒ Suppression de paquets pour signifier a congestion
 - Lorsque le routeur est saturé
 - ⇒ Suppression de tous les paquets

CE et fragmentation

- Si le paquet est marqué CE, alors le flag DF doit être positionné
- Si le paquet a été fragmenté, et que l'un des fragments est marqué CE, alors le marquage doit être reporté sur le paquet après réassemblage
- Le mécanisme CE ne doit pas être appliqué si un paquet est supprimé pour une autre raison que la congestion (erreur checksum, ...)

Indications TCP

- Bits ECE & CWR sont ajoutés au protocoles TCP
- Si marquage CE du paquet par la couche IP
⇒ Le bit ECE du segment est activé pour le prochain message ACK
- Si segment reçu avec flag ECE, alors gestion de congestion activée
⇒ Retour avec flag CWR → déclenchement slow-start
Informe R que la fenêtre de congestion a été réduite

Remarque : Pour activer le mécanisme dans TCP, indication lors de la phase de connexion :

$E \rightarrow \text{SYN} / \text{ECE} = 1 / \text{CWR} = 1$

$R \leftarrow \text{ACK} / \text{ECE} = 1 / \text{CWR} = 0$

Compléments Linux

Gestion réseau

- Pseudo répertoire /proc/net
 - ⇒ Pseudo fichiers réseau
 - arp ⇒ Table arp
 - dev ⇒ Statut des interfaces
 - route ⇒ Table de routage
 - sockstat ⇒ statistiques sur les sockets
 - ...

Gestion IP

- Pseudo répertoire `/proc/sys/net/ipv4`
 - ⇒ Fichiers de configuration de la communication ipv4
 - `ip_default_ttl`
 - `ip_forward`
 - `ip_unprivileged_port_start`
 - ...

Réseaux & Protocoles : TCP

Gestion TCP

- Pseudo répertoire `/proc/sys/net/ipv4`
 - ⇒ Fichiers de configuration des connexions TCP
 - `tcp_base_mss`
 - `tcp_frto`
 - `tcp_keepalive_time`
 - `tcp_sack`
 - ...

Informations ⇒ `man tcp`

Outil analyse réseau

- Fichiers de configuration & pages man
- Outils linux de base
 - ip ...
 - tcpdump
- Packages complémentaires
 - netstat ⇒ net-tools
 - nmap
 - netperf
 - bmon
 - darkstat
 - wireshark ⇒ Analyse réseau détaillée