



UNION INTERNATIONALE DES TÉLÉCOMMUNICATIONS

UIT-T

SECTEUR DE LA NORMALISATION
DES TÉLÉCOMMUNICATIONS
DE L'UIT

P.861

(08/96)

SÉRIE P: QUALITÉ DE TRANSMISSION
TÉLÉPHONIQUE

Méthodes d'évaluation objective et subjective de la qualité

**Mesure objective de la qualité des codecs
vocaux fonctionnant en bande téléphonique
(300 - 3400 Hz)**

Recommandation UIT-T P.861

(Antérieurement Recommandation du CCITT)

RECOMMANDATIONS UIT-T DE LA SÉRIE P
QUALITÉ DE TRANSMISSION TÉLÉPHONIQUE

Vocabulaire et effets des paramètres de transmission sur l'opinion des usagers	Série P.10
Lignes et postes d'abonnés	Série P.30 P.300
Normes de transmission	Série P.40
Appareils de mesures objectives	Série P.50 P.500
Mesures électroacoustiques objectives	Série P.60
Mesures de la sonie vocale	Série P.70
Méthodes d'évaluation objective et subjective de la qualité	Série P.80 P.800
Qualité audiovisuelle dans les services multimédias	Série P.900

Pour plus de détails, voir la Liste des Recommandations de l'UIT-T.

RECOMMANDATION UIT-T P.861

MESURE OBJECTIVE DE LA QUALITE DES CODECS VOCAUX FONCTIONNANT EN BANDE TELEPHONIQUE (300 - 3400 Hz)

Résumé

La présente Recommandation décrit une méthode objective pour estimer la qualité subjective des codecs vocaux utilisés dans la bande téléphonique (300 - 3400 Hz).

La présente Recommandation spécifie la production de signaux vocaux de source pour la mesure objective de leur qualité, ainsi que les conditions de référence pour lesquelles on a démontré que cette méthode de mesure objective de qualité fournissait des résultats valides. Elle spécifie également le calcul de la qualité objective sur la base de la mesure objective de qualité appelée *mesure de la qualité de parole perçue* (PSQM, *perceptual speech quality measure*), l'estimation de la qualité subjective à partir des résultats des mesures objectives et l'analyse de ces résultats.

La présente Recommandation peut être appliquée lors de l'évaluation des effets, sur la qualité subjective des codecs vocaux, de différents niveaux d'entrée de parole, de différents locuteurs, de différents débits et de différents transcodages.

Source

La Recommandation UIT-T P.861, élaborée par la Commission d'études 12 (1993-1996) de l'UIT-T, a été approuvée le 30 août 1996 selon la procédure définie dans la Résolution n° 1 de la CMNT.

Mots clés

Evaluation subjective de la qualité des paroles, mesure objective de la qualité des paroles.

AVANT-PROPOS

L'UIT (Union internationale des télécommunications) est une institution spécialisée des Nations Unies dans le domaine des télécommunications. L'UIT-T (Secteur de la normalisation des télécommunications) est un organe permanent de l'UIT. Il est chargé de l'étude des questions techniques, d'exploitation et de tarification, et émet à ce sujet des Recommandations en vue de la normalisation des télécommunications à l'échelle mondiale.

La Conférence mondiale de normalisation des télécommunications (CMNT), qui se réunit tous les quatre ans, détermine les thèmes d'études à traiter par les Commissions d'études de l'UIT-T lesquelles élaborent en retour des Recommandations sur ces thèmes.

L'approbation des Recommandations par les Membres de l'UIT-T s'effectue selon la procédure définie dans la Résolution n° 1 de la CMNT (Helsinki, 1^{er}-12 mars 1993).

Dans certains secteurs de la technologie de l'information qui correspondent à la sphère de compétence de l'UIT-T, les normes nécessaires se préparent en collaboration avec l'ISO et la CEI.

NOTE

Dans la présente Recommandation, l'expression «Administration» est utilisée pour désigner de façon abrégée aussi bien une administration de télécommunications qu'une exploitation reconnue.

© UIT 1996

Droits de reproduction réservés. Aucune partie de cette publication ne peut être reproduite ni utilisée sous quelque forme que ce soit et par aucun procédé, électronique ou mécanique, y compris la photocopie et les microfilms, sans l'accord écrit de l'UIT.

TABLE DES MATIÈRES

	Page	
1	Domaine d'application	1
2	Références	2
3	Abréviations	3
4	Définitions	3
5	Conventions	3
6	Résumé de la procédure de mesure objective.....	4
7	Préparation du matériel vocal source	4
7.1	Voix réelles.....	5
7.2	Voix artificielles	5
8	Sélection des paramètres expérimentaux.....	5
9	Calcul de la qualité objective	6
9.1	Initialisations globales	13
9.1.1	Alignement temporel.....	14
9.1.2	Échelonnement global	14
9.1.3	Étalonnage global.....	14
9.2	Correspondance temps-fréquence	15
9.2.1	Fenêtrage	15
9.2.2	Densité spectrale de puissance (SPD, spectral power density) échantillonnée.....	16
9.3	Prédistorsion et filtrage des fréquences.....	16
9.3.1	Densité de puissance fondamentale échantillonnée	16
9.3.2	Échelonnement local	17
9.3.3	Filtrage de la bande téléphonique.....	17
9.3.4	Bruit spectral de Hoth	17
9.4	Prédistorsion d'intensité.....	18
9.5	Modélisation cognitive	18
9.5.1	Échelonnement en sonie.....	19
9.5.2	Densité échantillonnée du bruit perturbateur	19
9.5.3	Traitement des asymétries	19
9.5.4	Traitement du bruit perturbateur, y compris les intervalles de silence	20
10	Transformation de l'échelle de qualité objective en échelle de qualité subjective	21
10.1	Notes moyennes d'opinion.....	21
10.2	Notes Q équivalentes	21
11	Analyse des résultats	22

	Page
Bibliographie	22
Appendice I – Contenu de la disquette accompagnant la Recommandation P.861.....	23
I.1 Introduction	23
I.2 Répertoire\src	23
I.3 Répertoire\test.....	24

Introduction

L'évaluation de la qualité subjective des codecs vocaux est une des techniques fondamentales qui permettent de concevoir des réseaux de télécommunication numériques. La Recommandation P.830 définit des méthodes subjectives d'essai pour codecs vocaux. Comme l'évaluation de la qualité subjective est coûteuse en termes de temps et d'argent, il est souhaitable de mettre au point une méthode d'évaluation objective de la qualité pour estimer la qualité subjective des codecs vocaux avec moins d'essais subjectifs.

Pour démontrer les performances des codecs vocaux, la mesure objective de qualité des signaux vocaux la plus communément utilisée est celle du rapport signal sur bruit (S/B). On fait toutefois observer que le rapport S/B ne prédit pas convenablement la qualité subjective pour composants de réseau modernes. Cela vaut particulièrement pour les récents codecs à bas débit. Diverses mesures objectives de qualité, plus élaborées, ont donc été mises au point, comme les suivantes: la mesure de la distance (CD) spectrale par codage LPC [1]; la méthode de l'indice d'information (II) [2]; la fonction de cohérence (CHF) [3]; la méthode de reconnaissance de formes par système expert (EPR, *expert pattern recognition*) [4] et la mesure de la qualité de la parole perçue (PSQM) [5]. La performance de ces systèmes, exprimée en termes de capacité à donner des estimations fidèles de la qualité subjective, font l'objet de recherches à l'UIT-T depuis les années 1980.

A la suite de comparaisons précises entre mesures objectives de qualité par ces méthodes, on a tiré la conclusion que la mesure PSQM présentait la meilleure corrélation avec la qualité subjective des paroles codées. La présente Recommandation décrit donc l'évaluation de qualité objective au moyen de la méthode PSQM [12].

Afin d'aider les lecteurs de la présente Recommandation à mettre au point leur propre réalisation de la mesure PSQM, une disquette a été jointe à la Recommandation. On trouvera une description du contenu de cette disquette dans le fichier README de celle-ci ainsi que dans l'Appendice I.

Recommandation P.861

MESURE OBJECTIVE DE LA QUALITE DES CODECS VOCAUX FONCTIONNANT EN BANDE TELEPHONIQUE (300 - 3400 Hz)

(Genève, 1996)

1 Domaine d'application

L'évaluation subjective de la qualité des codecs vocaux peut être effectuée au moyen de tests d'écoute seulement (dans un seul sens) ou au moyen de test de conversation (dans les deux sens). La mesure objective de qualité qui est décrite dans la présente Recommandation estime la qualité subjective lors d'essais d'écoute seulement.

Pour démontrer la performance subjective d'un codec, il faut examiner les effets de divers facteurs de qualité (voir la Recommandation P.830). L'exactitude de la mesure objective de qualité décrite dans la présente Recommandation n'a pas été vérifiée par examen de tous les facteurs spécifiés dans la Recommandation P.830. Le Tableau 1 est destiné à servir de guide pour faciliter la détermination, par le lecteur, des facteurs d'essai, des techniques de codage et des applications auxquelles cette Recommandation s'applique.

TABLEAU 1/P.861

Relation entre facteurs expérimentaux, techniques de codage et applications selon la présente Recommandation

Facteurs expérimentaux	Note
niveaux d'entrée des signaux de parole dans un codec	1
niveaux d'écoute lors d'expériences subjectives	2
variations selon le locuteur	1
locuteurs multiples simultanés	2
erreur de transmission dans la voie	2
débits lorsque le codec peut fonctionner selon plusieurs modes	1
transcodages	1
discordance de débit entre un codeur et un décodeur si un codec possède plusieurs modes de débit	2
bruit ambiant du côté émission	2
signaux d'information de couche réseau à l'entrée d'un codec	2
signaux de musique à l'entrée d'un codec	2
temps de propagation	3
prédistorsion à court terme du signal audio	2
prédistorsion à long terme du signal audio	4
écrêtage temporel du signal vocal	2
écrêtage en amplitude du signal vocal	2
Techniques de codage	
codecs temporels	1
codecs CELP et hybrides ≥ 4 kbit/s	1

TABLEAU 1/P.861

**Relation entre facteurs expérimentaux, techniques de codage et applications
selon la présente Recommandation**

codecs CELP et hybrides <4 kbit/s	2
vocodeurs	2
autres codeurs	2
Applications	
optimisation du codeur	1
évaluation du codeur	1
sélection du codeur	2
planification du réseau	5
essais actifs dans le réseau	6
dispositifs de mesure sans intrusion en service	3
NOTES	
<ol style="list-style-type: none"> 1 La mesure objective a montré une précision acceptable en présence de cette variable. 2 On ne dispose pas d'assez de renseignements au sujet de la précision de la mesure objective en ce qui concerne cette variable. 3 La mesure objective est réputée fournir des prédictions inexactes lorsqu'elle est utilisée conjointement avec cette variable ou n'est pas censée être utilisée avec cette variable. 4 La mesure objective est réputée fournir des prédictions inexactes en présence d'un dérapage assez important (plus de 10% de la longueur de trame). La possibilité d'appliquer la mesure en présence d'un dérapage moins important fera l'objet d'un complément d'étude. 5 Au prix de certaines précautions, on peut utiliser la mesure objective pour certains objets de planification de réseau. Le lecteur doit prendre acte du fait qu'il existe d'importants facteurs de planification de réseau auxquels la présente Recommandation n'est pas applicable (voir la section "Facteurs expérimentaux" du présent tableau). 6 Au prix de certaines précautions, on peut utiliser la méthode objective pour certains essais actifs sur le réseau. Le lecteur doit prendre acte du fait qu'il peut exister, dans une chaîne de connexion établie dans un réseau actif, des facteurs ou des techniques auxquels la présente Recommandation n'est pas applicable (voir les sections "Facteurs expérimentaux" et "Techniques de codage" du présent tableau). 	

Lorsque l'on compare un codec à un autre codec ou à une condition de référence fondée sur des résultats d'expériences subjectives, on fait souvent appel à des essais statistiques qui tiennent compte de la distribution des notes subjectives. Etant donné que, dans la présente Recommandation, la mesure objective n'estime que la moyenne des notes subjectives (par exemple notes MOS, notes DMOS), de tels essais statistiques ne peuvent pas être appliqués aux résultats de mesures objectives. La prédiction du pourcentage de notes au mieux médiocres (%PoW, *per cent poor or worse*) et du pourcentage de notes au moins bonnes (%GoB, *per cent good or better*) est actuellement à l'étude.

2 Références

Les Recommandations et autres références suivantes contiennent des dispositions qui, par suite de la référence qui y est faite, constituent des dispositions valables pour la présente Recommandation. Au moment de la publication, les éditions indiquées étaient en vigueur. Toutes Recommandations ou

autres références sont sujettes à révision; tous les utilisateurs de la présente Recommandation sont donc invités à rechercher la possibilité d'appliquer les éditions les plus récentes des Recommandations et autres références indiquées ci-après. Une liste des Recommandations UIT-T en vigueur est publiée régulièrement.

- Recommandation UIT-T P.50 (1993), *Voix artificielle*.
- Recommandation UIT-T P.800 (1996), *Méthodes d'évaluation subjective de la qualité de transmission*.
- Recommandation UIT-T P.810 (1996), *Appareil de référence à bruit modulé*.
- Recommandation UIT-T P.830 (1996), *Evaluation subjective de la qualité des codecs numériques à bande téléphonique et à large bande*.
- Recommandation G.711 du CCITT (1988), *Modulation par impulsions et codage (MIC) des fréquences vocales*.
- Recommandation G.726 du CCITT (1990), *Modulation par impulsions et codage différentiel adaptatif (MICDA) à 40, 32, 24, 16 kbit/s*.
- Recommandation G.728 du CCITT (1992), *Codage de la parole à 16 kbit/s en utilisant la prédiction linéaire à faible délai avec excitation par code*.
- Recommandation UIT-T G.729 (1996), *Codage de la parole à 8 kbit/s par prédiction linéaire avec excitation par séquences codées à structure algébrique conjuguée*.
- Supplément n° 13 des Recommandations de la série P du CCITT (1984), *Spectres de bruit*.

3 Abréviations

La présente Recommandation utilise les abréviations suivantes:

ACR	évaluation par catégories absolues (<i>absolute category rating</i>)
CELP	prédiction linéaire avec excitation par code (<i>code excited linear prediction</i>)
DCR	évaluation par catégories de dégradation (<i>degradation category rating</i>)
DMOS	note moyenne d'opinion de dégradation (<i>degradation mean opinion score</i>)
MOS	note moyenne d'opinion (<i>mean opinion score</i>)
PSQM	mesure de la qualité de parole perçue (<i>Perceptual Speech Quality Measure</i>)

4 Définitions

La présente Recommandation définit le terme suivant.

4.1 dBov: décibels par rapport au point de surcharge d'un système numérique

5 Conventions

L'évaluation subjective des codecs vocaux peut être conduite au moyen d'essais d'écoute seulement ou au moyen de méthodes d'essais subjectifs par conversation. Pour des raisons pratiques, les essais d'écoute seulement sont la seule méthode possible d'essais subjectifs au cours de la mise au point de codecs vocaux, lorsqu'une mise en oeuvre en temps réel de ces codecs n'est pas réalisable. La

présente Recommandation expose une technique de mesure objective qui permet d'estimer la qualité subjective obtenue lors d'essais d'écoute seulement.

6 Résumé de la procédure de mesure objective

La Figure 1 illustre la procédure de mesure objective.




FIGURE 1/P.861

Procédure de mesure objective de la qualité

La mesure objective de la qualité des codecs vocaux exige un certain nombre d'étapes:

- 1) préparation des matériaux de source, c'est-à-dire enregistrement des locuteurs et/ou production des voix artificielles conformément à la Recommandation P.50;
- 2) sélection des paramètres expérimentaux qui mettront à contribution les principales caractéristiques du codec et qui pourront être contrôlés par mesure objective;
- 3) production de signaux vocaux codés/de référence;
- 4) calcul de la qualité objective de la parole sur la base de la mesure de la qualité de parole perçue (PSQM), au moyen de signaux vocaux de source et codés;
- 5) transformation, si nécessaire, de l'échelle de qualité objective en échelle de qualité subjective;
- 6) analyse des résultats.

Chacune de ces étapes est décrite ci-dessous.

7 Préparation du matériel vocal source

Les signaux de source pour mesure objective peuvent être des voix réelles ou les voix artificielles spécifiées dans la Recommandation P.50, selon les buts de l'expérience.

Etant donné que les voix artificielles définies dans la Recommandation P.50 reproduisent les caractéristiques moyennes de la parole humaine dans diverses langues, ces voix sont utiles pour estimer objectivement la qualité subjective moyenne d'un codec utilisé avec ces langues. Lorsqu'il s'agit d'évaluer la relation d'un codec avec le locuteur ou la performance d'un codec pour des langues

particulières, il est recommandé d'utiliser des voix réelles. Dans un cas comme dans l'autre, aucun bruit ambiant ne doit être ajouté.

7.1 Voix réelles

Lorsque des voix réelles sont utilisées en mesure objective, ces voix doivent être produites, enregistrées et égalisées en niveau conformément à l'article 7/P.830.

Il est recommandé qu'un minimum de deux locuteurs de sexe masculin et deux locutrices de sexe féminin soient mis à contribution pour chaque condition d'essai. Si la relation avec le locuteur doit être évaluée en tant que facteur autonome, il est recommandé de faire appel à un plus grand nombre de locuteurs comme suit:

- 8 hommes;
- 8 femmes;
- 8 enfants.

7.2 Voix artificielles

Lorsqu'on utilise des voix artificielles conformes à la Recommandation P.50 pour une mesure objective, il est recommandé d'utiliser des voix artificielles aussi bien masculines que féminines. On doit faire passer ces signaux dans un filtre ayant des caractéristiques appropriées en fréquence afin de simuler la courbe de fréquence en émission d'un combiné téléphonique. Ces signaux doivent ensuite être égalisés en niveau comme les voix réelles (voir la Recommandation P.830).

L'UIT-T recommande l'utilisation de la caractéristique de fréquence d'émission par le système de référence intermédiaire (IRS, *intermediate reference system*) modifié, tel que défini dans l'Annexe D/P.830.

8 Sélection des paramètres expérimentaux

Pour démontrer la performance d'un codec, il y a lieu d'examiner les effets de divers facteurs de qualité sur cette performance. La Recommandation P.830 donne des directives sur l'évaluation subjective des facteurs de qualité ci-après:

- 1) niveaux d'entrée des signaux de parole dans un codec;
- 2) niveaux d'écoute lors d'expériences subjectives;
- 3) locuteurs (y compris multiples locuteurs simultanés);
- 4) erreurs dans la voie de transmission entre un codeur et un décodeur;
- 5) débits lorsque le codec peut fonctionner selon plusieurs modes;
- 6) transcodages;
- 7) désadaptation des débits entre un codeur et un décodeur si un codec possède plusieurs modes de débit;
- 8) bruit ambiant du côté émission;
- 9) signaux d'information de couche réseau à l'entrée d'un codec;
- 10) signaux musicaux à l'entrée d'un codec.

Etant donné que la mesure objective de qualité décrite dans la présente Recommandation part du principe:

- 1) que les signaux source de parole sont "propres" (c'est-à-dire sans bruit ambiant ajouté du côté émission); et

- 2) qu'il n'y a aucune dégradation de voie telle que des erreurs sur les bits de transmission, des effacements de trame (comme cela peut être le cas dans des applications de radiocommunications mobiles), ou des pertes de cellules (comme cela peut être le cas dans les réseaux en mode ATM),

les facteurs de qualité auxquels la présente Recommandation s'applique sont les niveaux d'entrée des signaux de parole, les locuteurs (sauf les multiples locuteurs simultanés), les débits et les transcodages.

NOTE 1 – La mesure objective de facteurs de qualité autres que ceux qui sont expressément indiqués dans la présente Recommandation comme étant applicables est encore à l'étude. Ces facteurs ne devront donc être mesurés qu'après vérification de l'exactitude de la mesure objective en liaison avec les essais subjectifs selon la Recommandation P.830.

NOTE 2 – Bien que certains éléments donnent à penser que la mesure objective peut prédire avec précision la qualité en conditions de dégradation des voies [10] [11], l'applicabilité de cette mesure à ces conditions est encore à l'étude.

En plus des conditions du codec, la Recommandation P.830 recommande d'utiliser des conditions de référence lors des essais subjectifs. Ces conditions sont nécessaires pour faciliter la comparaison des résultats d'essais subjectifs issus de différents laboratoires ou du même laboratoire à différentes dates. De même, lorsqu'on exprime les résultats d'essais subjectifs en termes de notes Q équivalentes, il convient de rapporter les essais aux conditions de référence au moyen de l'appareil de référence à bruit modulé (MNRU, *modulated noise reference unit*) qui est spécifié dans la Recommandation P.810.

NOTE 3 – L'inclusion dans les mesures objectives de qualité d'autres codecs normalisés tels qu'à codages MIC G.711 à 64 kbit/s, MICDA G.726 à 32 kbit/s, LD-CELP G.728 à 16 kbit/s et CS-ACELP G.729 à 8 kbit/s, ainsi que de l'appareil MNRU, peut contribuer à démontrer la performance relative du codec à l'essai et des codecs normalisés.

La Recommandation P.830 contient des explications détaillées sur ces paramètres expérimentaux.

9 Calcul de la qualité objective

Cet article décrit une méthode de mesure de la qualité des signaux de parole codés dans la bande téléphonique (300 - 3400 Hz) au moyen de la mesure de qualité de la parole perçue (PSQM). La mesure PSQM consiste à simuler la perception acoustique de sujets placés en situation de la vie réelle [6]. La mesure PSQM simule des expériences au cours desquelles des sujets évaluent la qualité de codecs vocaux. Pour cela, elle compare un signal codé à un signal source (Figure 2). Bien que ce principe fondamental de comparaison soit particulièrement adapté aux essais d'évaluation par catégories de dégradation (DCR), on peut simuler des expériences d'évaluation par catégories absolues (ACR) comme indiqué dans les essais de validation [12]. Dans la mesure où la mesure PSQM est une représentation fidèle des processus de perception et de jugement humains, des différences inaudibles entre entrée et sortie feront l'objet de notes identiques en mesure PSQM. En particulier, si l'entrée et la sortie sont identiques, la mesure PSQM prédira une qualité parfaite sans tenir compte de la qualité du signal d'entrée.

Dans le cadre de la mesure PSQM, les signaux physiques constituant les paroles de source et les paroles codées sont appliqués sur des représentations psychophysiques aussi proches que possible des représentations internes des signaux de parole (tels qu'ils sont perçus par le cerveau humain). Ces représentations internes font appel aux équivalents psychophysiques de la fréquence (niveaux de bande critique) et de l'intensité (équivalents pour la sonie comprimés). Le masquage est modélisé de manière simple: il n'est pris en compte que lorsque deux composantes de temps-fréquence coïncident dans les deux domaines, temps et fréquence.

Dans la méthode de mesure PSQM, la qualité des paroles codées est jugée sur la base de différences entre représentations internes. Ces différences permettent de calculer le bruit perturbateur en fonction du temps et de la fréquence. Dans la méthode de mesure PSQM, le bruit perturbateur moyen est directement associé à la qualité de la parole codée.

La transformation du domaine physique (externe) au domaine psychophysique (interne) s'effectue en trois phases comme suit:

- mise en correspondance temps-fréquence;
- prédistorsion en fréquence;
- prédistorsion en intensité (compression).

En plus de la modélisation perceptive, la mesure PSQM fait appel à la modélisation cognitive [7] afin d'obtenir d'importants coefficients de corrélation entre mesures subjectives et objectives.

La Figure 3 montre schématiquement l'algorithme PSQM.

Tous les paramètres et toutes les variables du présent article sont résumés dans le Tableau 2, dans le Tableau 3 et dans le Tableau 4.




FIGURE 2/P.861

Aperçu général des principes fondamentaux suivis lors de l'élaboration de la méthode PSQM – Un modèle informatique du sujet, composé d'un modèle perceptif et d'un modèle cognitif, est utilisé pour comparer la sortie du codec vocal à son entrée

TABLEAU 2/P.861

Liste des paramètres en mesure PSQM

Nom	Description	Valeur
Nb	nombre de bandes dans le domaine des bandes critiques (de Bark)	(voir Tableau 4)
Nf	nombre d'échantillons dans une trame temporelle	512 pour une fréquence d'échantillonnage de 16 kHz 256 pour une fréquence d'échantillonnage de 8 kHz
F[j]	réponse en fréquence du combiné à la réception	système IRS selon Recommandation P.830 (le Tableau 4 contient la fonction de transfert de puissance pour le système IRS)
H[j]	caractéristiques de bruit spectral de Hoth	(le Tableau 4 contient la puissance additive correspondant à la caractéristique de bruit spectral de Hoth)
P ₀ [j]	seuil absolu d'audition	(le Tableau 4 contient la représentation équivalente en puissance de P ₀ [j])
Δf[j]	largeur de bande de la bande j en Hertz	(voir Tableau 4)
Δz	largeur de chaque sous-bande dans le domaine des bandes critiques	0,312
γ	exposant de la fonction de compression	0,001
W _{sil}	facteur de pondération sur trames de silence	0,2 (provisoire)
W _{sp}	facteur de pondération sur trames de conversation active	$W_{sp} = (1 - W_{sil})/W_{sil} = 4,0$ (provisoire)




FIGURE 3/P.861

Schéma fonctionnel de l'algorithme PSQM

TABLEAU 3/P.861

Variables utilisées dans la méthode PSQM

Nom	Description
m	index dans le domaine temporel
n	index dans le domaine temporel pour une trame (n: 1, 2, 3, , Nf)
i	index pour les trames
j	index dans le domaine fréquentiel prédistordu (domaine des bandes critiques) (j: 1, 2, 3, , Nb)
k	index dans le domaine fréquentiel (Hz) (k: 1, 2, 3, , Nf/2)
x[m]	version alignée temporellement et étalonnée globalement du signal vocal de source échantillonné
y[m]	version alignée temporellement, échelonnée globalement et étalonnée globalement du signal vocal codé et échantillonné
S _{global}	facteur d'échelonnement en échelonnement global
S _p	facteur d'étalonnage de la puissance fondamentale
S _l	facteur d'étalonnage de la sonie fondamentale
x _i [n]	x[m] dans la trame I
y _i [n]	y[m] dans la trame I
xw _i [n]	version fenêtrée de x _i [n]
yw _i [n]	version fenêtrée de y _i [n]
X _i [k]	transformée FFT de xw _i [n]
Y _i [k]	transformée FFT de yw _i [n]
Px _i [k]	densité SPD de xw _i [n]
Py _i [k]	densité SPD de yw _i [n]
I _i [j]	indice de transformée de Fourier rapide (FFT) de la première valeur de k pour Px _i [k] et Py _i [k] dans la bande j
I _i [j]	indice de transformée de Fourier rapide (FFT) de la dernière valeur de k pour Px _i [k] et Py _i [k] dans la bande j
Px' _i [j]	densité de puissance fondamentale échantillonnée de xw _i [n]
Py' _i [j]	densité de puissance fondamentale échantillonnée de yw _i [n]
Px' _i	puissance du signal vocal de source dans la trame I
Py' _i	puissance du signal vocal codé dans la trame I
Py'' _i [j]	version échelonnée localement de Py' _i [j]
Pfx _i [j]	version filtrée en bande téléphonique de Px' _i [j]
PFy _i [j]	version filtrée en bande téléphonique de Py'' _i [j]
PHx _i [j]	PFx _i [j] plus bruit spectral de Hoth en tant que bruit ambiant (en réception)
PHy _i [j]	PFy _i [j] plus bruit spectral de Hoth en tant que bruit ambiant (en réception)
S _i	facteur d'échelonnement lors de l'échelonnement local dans la trame i
S _{av}	moyenne (arithmétique) de S _i
Lx _i [j]	densité d'équivalents pour la sonie comprimés après échantillonnage du signal vocal de source dans la trame i et dans la bande j

TABLEAU 3/P.861

Variables utilisées dans la méthode PSQM

Nom	Description
$Ly_i[j]$	densité d'équivalents pour la sonie comprimés après échantillonnage du signal vocal codé dans la trame i et dans la bande j
Lx_i	valeur instantanée des équivalents pour la sonie comprimés du signal vocal de source dans la trame i
Ly_i	valeur instantanée des équivalents pour la sonie comprimés du signal vocal codé dans la trame i
Sl_i	facteur d'échelonnement en termes de sonie dans la trame I
$Ly'_i[j]$	version échelonnée en sonie de $Ly_i[j]$
$N_i[j]$	densité de bruit perturbateur échantillonnée dans la trame i et dans la bande j
$C_i[j]$	facteur d'effet asymétrique dans la trame i et dans la bande j
N_i	bruit perturbateur dans la trame I
N_{wsil}	bruit perturbateur moyen avec pondération des trames de silence
M_{sp}	nombre de trames de conversation active
M_{sil}	nombre de trames de silence
N_{spav}	valeur moyenne de N_i dans les trames de conversation active
N_{silav}	valeur moyenne de N_i dans les trames de silence

TABLEAU 4/P.861

Attribution de fréquences dans les bandes critiques et caractéristiques des filtres correspondants (sur la base d'une fréquence d'échantillonnage de 16 kHz)

Numéro de la bande, j	Fréquence supérieure [Hz]	Premier segment de transformée FFT dans la bande j, I _f	Dernier segment de transformée FFT dans la bande j, I _l	Caractéristique de réception, F	Seuil d'audition P ₀	Bruit spectral de Hoth, H
0	15,6	0	0	valeurs éliminées lors du traitement		
1	46,9	1	1	2,45E-06	3,89E+07	1,72E+04
2	78,1	2	2	9,24E-06	1,12E+06	1,72E+04
3	109,4	3	3	3,56E-05	1,26E+05	1,72E+04
4	140,6	4	4	2,59E-04	1,86E+04	1,22E+04
5	171,9	5	5	1,18E-03	6,17E+03	8,49E+03
6	203,1	6	6	7,48E-03	2,29E+03	6,31E+03
7	234,4	7	7	3,19E-02	9,33E+02	4,91E+03
8	265,6	8	8	7,31E-02	4,37E+02	3,95E+03
9	296,9	9	9	1,37E-01	2,29E+02	3,26E+03
10	328,1	10	10	2,09E-01	1,29E+02	2,74E+03
11	359,4	11	11	2,93E-01	7,76E+01	2,35E+03
12	390,6	12	12	4,25E-01	4,27E+01	2,04E+03
13	421,9	13	13	5,23E-01	3,02E+01	1,79E+03
14	453,1	14	14	5,98E-01	2,19E+01	1,59E+03
15	484,8	15	15	6,51E-01	1,66E+01	1,44E+03
16	519,2	16	16	6,94E-01	1,32E+01	1,39E+03
17	553,6	17	17	7,31E-01	1,07E+01	1,25E+03
18	590,8	18	18	7,66E-01	8,91E+00	1,22E+03
19	631,2	19	20	7,98E-01	7,59E+00	1,19E+03
20	672,9	21	21	8,37E-01	6,31E+00	1,10E+03
21	716,6	22	22	8,63E-01	5,62E+00	1,04E+03
22	760,4	23	24	8,88E-01	5,13E+00	9,45E+02
23	804,6	25	25	9,12E-01	4,68E+00	8,69E+02
24	851,4	26	27	9,35E-01	4,37E+00	8,41E+02
25	898,3	28	28	9,56E-01	4,17E+00	7,68E+02
26	947,0	29	30	9,71E-01	4,07E+00	7,33E+02
27	997,0	31	31	9,80E-01	3,98E+00	6,90E+02
28	1 051,	32	33	9,87E-01	3,98E+00	6,87E+02
29	1 108,	34	35	9,90E-01	3,98E+00	6,57E+02
30	1 168,	36	37	9,91E-01	3,98E+00	6,49E+02
31	1 231,	38	39	9,93E-01	3,98E+00	6,17E+02
32	1 297,	40	41	9,95E-01	4,07E+00	5,95E+02
33	1 366,	42	43	1,00E+00	4,27E+00	5,68E+02
34	1 437,	44	45	1,01E+00	4,47E+00	5,37E+02

TABLEAU 4/P.861

Attribution de fréquences dans les bandes critiques et caractéristiques des filtres correspondants (sur la base d'une fréquence d'échantillonnage de 16 kHz)

Numéro de la bande, j	Fréquence supérieure [Hz]	Premier segment de transformée FFT dans la bande j, I _f	Dernier segment de transformée FFT dans la bande j, I _l	Caractéristique de réception, F	Seuil d'audition P ₀	Bruit spectral de Hoth, H
35	1 509,	46	48	1,02E+00	4,68E+00	5,04E+02
36	1 582,	49	50	1,04E+00	5,01E+00	4,80E+02
37	1 658,	51	53	1,06E+00	5,37E+00	4,51E+02
38	1 736,	54	55	1,07E+00	5,62E+00	4,37E+02
39	1 817,	56	58	1,09E+00	5,89E+00	4,20E+02
40	1 902,	59	60	1,10E+00	6,31E+00	4,05E+02
41	1 991,	61	63	1,11E+00	6,61E+00	3,97E+02
42	2 084,	64	66	1,12E+00	6,92E+00	3,86E+02
43	2 184,	67	69	1,12E+00	7,24E+00	3,82E+02
44	2 289,	70	73	1,12E+00	7,59E+00	3,74E+02
45	2 401,	74	76	1,11E+00	7,76E+00	3,67E+02
46	2 520,	77	80	1,10E+00	7,94E+00	3,63E+02
47	2 647,	81	84	1,08E+00	7,94E+00	3,56E+02
48	2 781,	85	88	1,01E+00	7,94E+00	3,46E+02
49	2 922,	89	93	8,62E-01	7,94E+00	3,37E+02
50	3 069,	94	98	6,86E-01	8,13E+00	3,25E+02
51	3 225,	99	103	5,16E-01	8,13E+00	3,16E+02
52	3 392,	104	108	3,12E-01	8,32E+00	2,92E+02
53	3 572,	109	114	1,55E-01	8,32E+00	2,69E+02
54	3 765,	115	120	3,02E-02	8,32E+00	2,47E+02
55	3 971,	121	127	2,03E-03	8,32E+00	2,25E+02
56	4 193,	128	134	1,52E-04	8,32E+00	2,06E+02

NOTES

1 Le seuil absolu, P₀, utilise l'étalonnage 0 dBa =1,0.

2 La première fréquence supérieure (15,6 Hz) équivaut à la valeur 0,156 d'une bande critique. La largeur de bande Δz est égale à la valeur 0,312 d'une bande critique.

9.1 Initialisations globales

Avant de commencer le calcul du bruit perturbateur, qui est obtenu à la sortie de l'algorithme PSQM, les initialisations globales ci-après doivent être effectuées pour chaque paire (avant et après codage) de signaux de parole:

- alignement temporel;
- échelonnement global pour la compensation du gain systématique;
- étalonnage global pour le réglage de la sonie des signaux vocaux.

Etant donné que les codecs vocaux en bande téléphonique adoptent généralement une fréquence d'échantillonnage de 8 kHz à l'entrée, la présente Recommandation part du principe que les signaux vocaux de source comme codés ont une fréquence d'échantillonnage de 8 kHz ou de 16 kHz (c'est-à-dire après suréchantillonnage d'un facteur 2).

9.1.1 Alignement temporel

La première initialisation globale qui doit être effectuée est l'alignement temporel du signal source $x[m]$ et du signal codé $y[m]$. Si ces signaux ne sont pas correctement alignés, la méthode PSQM ne peut pas être appliquée.

Lorsque l'on ne connaît pas la valeur théorique du retard du signal codé par rapport au signal source, on peut utiliser le retard qui donne la corrélation maximale entre les deux signaux afin d'estimer cette valeur. Pour les signaux subissant une distorsion du temps de propagation de groupe, le retard qui donne la plus petite valeur de mesure PSQM est celui qu'il faut retenir.

Au cours du traitement des signaux, on élimine les zéros de tête et de queue dans le fichier de parole puis on calcule les points de départ et d'arrêt en détectant l'activité vocale sur la base du seul signal de source. Les algorithmes permettant de déterminer le premier et le dernier échantillon de conversation active sont les suivants.

Lorsque l'on détermine le début d'une conversation active dans un fichier, le premier échantillon à déclarer actif est celui dont l'effectif (c'est-à-dire la valeur absolue), plus les effectifs des quatre échantillons précédents, a une valeur totale d'au moins 200. (Aux fins des essais des quatre premiers échantillons pour déterminer le début d'une conversation, les échantillons qui précèdent le premier échantillon sont considérés comme ayant la valeur 0.)

Lorsque l'on détermine la fin d'une conversation active dans un fichier, le dernier échantillon déclaré actif est le dernier échantillon dont l'effectif (c'est-à-dire la valeur absolue), plus celui des quatre échantillons suivants, a une valeur totale d'au moins 200. (Aux fins des essais des quatre derniers échantillons pour déterminer la fin d'une conversation, les échantillons qui suivent le dernier échantillon sont considérés comme ayant la valeur 0.)

9.1.2 Échelonnement global

Après le processus d'alignement temporel, le signal codé $y[m]$ est échelonné afin de compenser le gain global du système. Le facteur d'échelonnement S_{global} est défini comme suit:

$$S_{global} = \sqrt{\frac{\sum_{\text{point de départ}}^{\text{point d'arrêt}} x^2[m]}{\sum_{\text{point de départ}}^{\text{point d'arrêt}} y^2[m]}}$$

Le signal codé $y[m]$ est ensuite multiplié par le facteur S_{global} .

9.1.3 Etalonnage global

Pour assurer une exactitude optimale de la mesure objective, il est nécessaire d'effectuer un étalonnage entre le niveau d'écoute et la sonie comprimée. Les valeurs indiquées dans le Tableau 4 sont fondées sur l'hypothèse qu'un niveau de pression acoustique = 0 dB est équivalent à une valeur maximale de 1,0 dans le domaine des puissances de fondamentale telles que calculées au 9.3.1 [c'est-à-dire $\max_j(Px_i[j]) = 1,0$ pour une trame donnée]. On suppose également que le niveau d'écoute optimal de 78 dB acoustique est utilisé conjointement avec les fichiers de parole qui ont un niveau de conversation active égal à -26 dBov, comme indiqué dans la Recommandation P.830.

Les étalonnages sont effectués avec une onde sinusoïdale de 1 kHz à un niveau acoustique de 40 dB (c'est-à-dire -64 dBov). Il est préférable d'utiliser, à cette fin, une onde sinusoïdale réelle (c'est-à-dire composée de valeurs non entières) afin d'éviter des phénomènes de quantification lors de l'application de la fonction d'étalonnage. Un niveau acoustique de 40 dB correspond à une amplitude zéro à crête de 29,54.

Le premier étalonnage consiste à échelonner à 10 000 la valeur maximale de la représentation de puissance fondamentale contenue dans l'onde d'étalonnage [c'est-à-dire, si la valeur $\max_j(Px'_i[j]) = 1,0$ pour un niveau acoustique de 0 dB, cette valeur $\max_j(Px'_i[j]) = 10\,000$ pour un niveau acoustique de 40 dB]. Ce facteur d'étalonnage, S_p , est calculé comme suit:

$$S_p = \frac{10000}{\max_j(Px'_i[j])}$$

lorsque la valeur $Px'_i[j]$ (voir 9.3.1) est calculée pour l'onde d'étalonnage. Dans une mise en oeuvre de la mesure PSQM où la transformée FFT est échelonnée par un facteur n (comme dans la routine disponible sur le marché "four1" issue des *Numerical Recipes in C* [13],

$$S_p = 6,4661 e^{-06}$$

Le deuxième étalonnage fixe à la valeur 1,0 Sone la sonie comprimée de l'onde d'étalonnage, telle que calculée au 9.4. Ce facteur d'étalonnage est calculé comme suit:

$$S_l = \frac{1}{Lx_i}$$

lorsque l'on calcule Lx_i pour l'onde d'étalonnage. Si le premier étalonnage est effectué correctement, on obtient $S_l = 240,05$.

NOTE 1 – Il y a lieu que la tonalité d'étalonnage ne soit pas filtrée par la caractéristique de réception, F , ni qu'on lui ajoute du bruit spectral de Hoth avant le calcul des facteurs Lx_i et S_l . Cette exception ne vaut que pour les opérations d'étalonnage.

Si le niveau de conversation active dans le fichier numérique n'est pas égal à -26 dBov, ou si le niveau acoustique d'écoute n'est pas égal à 78 dB, il y a lieu d'échelonner les données d'entrée en conséquence.

NOTE 2 – Dans un fichier numérique en mots de 16 éléments binaires, le niveau 0 dBov est représenté par une composante constante de 32 767. Une onde sinusoïdale ayant une amplitude zéro à crête de 32 767 aura donc un niveau efficace de -3,01 dBov. Avec les hypothèses adoptées dans ce paragraphe, cette valeur correspondra à un niveau acoustique d'environ 101 dB.

9.2 Correspondance temps-fréquence

Le passage du domaine temporel au domaine fréquentiel est mis en oeuvre au moyen d'une transformée de Fourier à court terme insérée dans une fenêtre de Hanning produisant une représentation du temps et de la fréquence ayant une résolution constante dans le domaine temporel comme dans le domaine fréquentiel.

9.2.1 Fenêtrage

Le signal source $x_i[n]$ et le signal codé $y_i[n]$ dans la trame i sont insérés dans une fenêtre de Hanning (\sin^2):

$$xw_i[n] = w[n] \cdot x_i[n]$$

$$yw_i[n] = w[n] \cdot y_i[n]$$

où $w[n]$ est la fonction de fenêtrage.

La fonction de fenêtrage peut se calculer comme suit:

$$w[n] = 0,5 \left(1 - \cos \left(\frac{2\pi n}{Nf} \right) \right) \text{ pour } 0 \leq n \leq Nf - 1$$

Dans tout l'article 9, tous les calculs sont définis sur une base de trame individuelle. On doit utiliser une longueur de trame de 256 échantillons pour une fréquence de 8 kHz et de 512 échantillons pour une fréquence de 16 kHz, ce qui correspond à peu près à la longueur de fenêtre de l'oreille humaine. Par ailleurs, les trames adjacentes doivent se chevaucher d'environ 50%.

9.2.2 Densité spectrale de puissance (SPD, *spectral power density*) échantillonnée

Les densités spectrales de puissance des signaux $xw_i[n]$ et $yw_i[n]$, représentées par $Px_i[k]$ et $Py_i[k]$, sont calculées au moyen des transformées de Fourier rapides (FFT) suivantes:

$$\begin{aligned} xw_i[n] &\Rightarrow FFT \Rightarrow X_i[k] \\ yw_i[n] &\Rightarrow FFT \Rightarrow Y_i[k] \\ Px_i[k] &= (\text{Re } X_i[k])^2 + (\text{Im } X_i[k])^2 \\ Py_i[k] &= (\text{Re } Y_i[k])^2 + (\text{Im } Y_i[k])^2 \end{aligned}$$

9.3 Prédistorion et filtrage des fréquences

Ce paragraphe décrit d'abord la prédistorion permettant de passer de l'échelle en hertz à l'échelle des bandes critiques, pour obtenir une représentation de la densité de puissance fondamentale échantillonnée trame par trame. La densité de puissance fondamentale échantillonnée dans le signal codé est échelonnée dans chaque trame. Ensuite, les signaux, de source et codé, sont tous les deux filtrés en bande téléphonique et le bruit spectral de Hoth est ajouté pour simuler l'environnement d'écoute. Finalement, les signaux sont filtrés par la fonction de transfert caractéristique entre l'oreille externe et l'oreille interne.

9.3.1 Densité de puissance fondamentale échantillonnée

L'index de fréquence k , exprimé en hertz, est transformé en index tonal j dans le domaine des bandes critiques, au moyen d'une prédistorion de l'échelle des fréquences. L'échelle des bandes critiques est d'abord subdivisée en bandes d'intervalle égal et, pour chaque bande, on calcule une valeur (échantillon) de densité de puissance fondamentale, à partir des échantillons (habituellement multiples) de densité de puissance spectrale dans la bande correspondante sur l'échelle en hertz. Les densités de puissance fondamentale échantillonnée, $Px'_i[j]$ et $Py'_i[j]$ pour la bande j dans la trame i sont données par les formules suivantes:

$$\begin{aligned} Px'_i[j] &= S_p \cdot \frac{\Delta f_j}{\Delta z} \cdot \frac{1}{I_l[j] - I_f[j] + 1} \cdot \sum_{I_f[j]}^{I_l[j]} Px_i[k] \\ Py'_i[j] &= S_p \cdot \frac{\Delta f_j}{\Delta z} \cdot \frac{1}{I_l[j] - I_f[j] + 1} \cdot \sum_{I_f[j]}^{I_l[j]} Py_i[k] \end{aligned}$$

où $I_f[j]$ est l'index du premier et $I_l[j]$ celui du dernier échantillon sur l'échelle hertzienne pour la bande j , Δz étant la largeur de chaque sous-bande dans le domaine des bandes critiques, et S_p étant le facteur d'étalonnage de la puissance fondamentale tel qu'indiqué au 9.1.3.

9.3.2 Échelonnement local

Les signaux source et codé doivent être échelonnés dans le cadre de chaque trame, afin de compenser les variations lentes du gain. Seules les composantes fréquentielles audibles sont prises en compte (au-dessus du seuil absolu d'audibilité pour chaque bande $P_d[j]$ définie dans le Tableau 4). Les puissances totales des signaux source et codé dans une trame i , Px'_i et Py'_i , sont calculées à l'aide de la représentation après prédistorsion fréquentielle:

$$Px'_i = \sum_{j=1}^{Nb} Px_i[j]$$
$$Py'_i = \sum_{j=1}^{Nb} Py_i[j]$$

où Nb est le nombre total de bandes.

Lorsque les deux puissances, celle du signal source Px'_i et celle du signal codé Py'_i se trouvent au-dessus du niveau acoustique de 40 dB, la puissance du signal codé pour la bande j , $Py'_i[j]$, est multipliée par un facteur d'échelonnement S_i :

$$Py''_i[j] = S_i \cdot Py'_i[j]$$

où

$$S_i = \frac{Px'_i}{Py'_i}$$

Lorsque soit la puissance du signal source Px'_i soit celle du signal codé Py'_i est inférieure à 40 dBa, la puissance du signal codé pour la bande j , $Py'_i[j]$, est multipliée par un facteur d'échelonnement S_{av} qui est la moyenne de tous les facteurs S_i calculés précédemment.

9.3.3 Filtrage de la bande téléphonique

On doit filtrer les composantes $Px'_i[j]$ et $Py''_i[j]$ au moyen des caractéristiques de réception appropriées à un combiné téléphonique:

$$PFx_i[j] = F[j] \cdot Px'_i[j]$$

$$PFy_i[j] = F[j] \cdot Py''_i[j]$$

où $F[j]$ est la réponse en fréquence dans la bande j des caractéristiques de réception d'un combiné. L'UIT-T recommande d'utiliser la courbe de réception de l'appareil IRS modifié, définies dans l'Annexe D/P.830 en tant que caractéristiques de fréquence de réception d'un combiné téléphonique. Les valeurs de $F[j]$ pour ces caractéristiques sont indiquées dans le Tableau 4.

9.3.4 Bruit spectral de Hoth

En utilisation téléphonique normale, le signal vocal est perturbé par des sons ambiants issus de l'environnement de réception. Dans le cadre de la mesure PSQM, cet effet est modélisé par adjonction d'un bruit spectral de Hoth au signal de source comme au signal codé. Le bruit spectral de Hoth [8] est ajouté à la densité de puissance fondamentale échantillonnée pour chaque valeur de j , au moyen de la fonction de densité de puissance spectrale comme indiqué dans la Recommandation P.800:

$$PHx_i[j] = H[j] \cdot PFX_i[j]$$

$$PHY_i[j] = H[j] \cdot PFY_i[j]$$

où $H[j]$ est la puissance du bruit de Hoth dans la bande j indiquée dans le Tableau 4.

NOTE – Toutes les validations de la méthode PSQM par l'UIT-T ont été effectuées avec un bruit de Hoth à un niveau de 45 dBa.

9.4 Prédistorion d'intensité

Après le calcul des densités de puissance fondamentale échantillonnée, compte tenu du filtrage en bande téléphonique et de l'insertion du bruit spectral de Hoth, l'échelle des intensités est transformée en échelle des sonies de façon à obtenir une fonction de densité de sonie comprimée et échantillonnée.

Les densités de sonie comprimée et échantillonnée, $Lx_i[j]$ et $Ly_i[j]$, sont calculées à partir des densités de puissance fondamentale $PHx_i[j]$ et $PHy_i[j]$, au moyen d'une fonction de compression donnée comme suit par Zwicker [9]:

$$Lx_i[j] = S_l \cdot \left(\frac{P_0[j]}{0,5} \right)^\gamma \cdot \left[\left(0,5 + 0,5 \cdot \frac{PHx_i[j]}{P_{0<[j]}} \right)^\gamma - 1 \right]$$

$$Ly_i[j] = S_l \cdot \left(\frac{P_0[j]}{0,5} \right)^\gamma \cdot \left[\left(0,5 + 0,5 \cdot \frac{PHy_i[j]}{P_{0[j]}} \right)^\gamma - 1 \right]$$

où $P_0[j]$ est le seuil interne indiqué dans le Tableau 4 et où S_l est le facteur d'étalonnage en sonie fondamentale tel qu'exposé au 9.1.3. Les valeurs négatives de $Lx_i[j]$ et de $Ly_i[j]$ sont mises à zéro.

La valeur optimale de γ , trouvée lors d'optimisations utilisant des bases de données construites par différentes expériences d'évaluation de la qualité de la parole, est de 0,001.

Les valeurs instantanées (totales) des sonies comprimées Lx_i et Ly_i (exprimées en sonies comprimées) sont calculées par sommation des densités comprimées et échantillonnées $Lx_i[j]$ et $Ly_i[j]$:

$$Lx_i = \sum_{j=1}^{Nb} Lx_i[j] \cdot \Delta z$$

$$Ly_i = \sum_{j=1}^{Nb} Ly_i[j] \cdot \Delta z$$

où Δz est la largeur de bande dans le domaine des bandes critiques. Les valeurs instantanées des sonies comprimées, Lx_i et Ly_i , sont utilisées lors de la modélisation cognitive.

9.5 Modélisation cognitive

Dans le contexte de la mesure PSQM, toutes les opérations qui ne peuvent pas être exécutées sur le signal source seul ou sur le signal codé seul sont définies comme étant des opérations cognitives. Quatre effets cognitifs sont examinés dans le présent paragraphe:

- l'échelonnement en sonie;
- la densité échantillonnée du bruit perturbateur (cognitif interne);
- le traitement des asymétries;
- le traitement du bruit perturbateur y compris les intervalles de silence.

9.5.1 Échelonnement en sonie

Dans le contexte de la mesure PSQM, la densité de sonie comprimée et échantillonnée du signal codé est échelonnée, dans chaque trame, par rapport à la sonie du signal source:

$$Ly'_i = Sl_i \cdot Ly_i[j]$$

où le facteur d'échelonnement Sl_i est calculé à partir des valeurs instantanées (totales) des sonies comprimées Lx_i et Ly_i :

$$Sl_i = \frac{Lx_i}{Ly_i}$$

Lorsque Lx_i ou Ly_i a une valeur inférieure à 0,02 (en sone comprimé), la composante Sl_i est mise à égalité avec 1.

9.5.2 Densité échantillonnée du bruit perturbateur

La densité échantillonnée du bruit perturbateur $N_i[j]$ dans la bande j et dans la trame i est calculée comme étant la différence absolue entre les composantes $Lx_i[j]$ et $Ly'_i[j]$:

$$N_i[j] = |Ly'_i[j] - Lx_i[j]| - 0.01$$

où le facteur 0,01 (en sone comprimé) représente le bruit cognitif interne. Si, en raison de ce facteur, la valeur de $N_i[j]$ devient négative, cette valeur de $N_i[j]$ est mise à égalité avec zéro.

9.5.3 Traitement des asymétries

Lorsqu'une nouvelle composante fréquentielle est introduite dans le signal de parole, la qualité subjective se révèle plus dégradée que lorsqu'une composante de sonie égale est négligée par le codec vocal. Cette asymétrie est plus évidente lors des intervalles de silence. Le bruit qui est présent dans le signal source peut être annulé, ce qui provoque une amélioration de la qualité. S'il n'y a pas de bruit au cours des intervalles de silence contenus dans le signal de source, toute différence entre signaux vocaux de source et codés conduira à une dégradation de la qualité.

En outre, lorsqu'une composante fréquentielle est négligée dans le signal de source (non codé par le codec), le signal restant reste un événement acoustique cohérent. Si une nouvelle composante fréquentielle indépendante (distorsion) est insérée dans le signal codé, le nouveau signal ainsi formé peut être décomposé en deux parties: le signal original et la distorsion. Cette décomposition du flux acoustique rend le bruit plus gênant.

L'effet d'asymétrie est quantifié par $C_i[j]$ et pris en compte dans le bruit perturbateur présent dans la trame i , N_i :

$$N_i = \sum_{j=1}^{Nb} N_i[j] \cdot C_i[j] \cdot \Delta z$$

où

$$C_i[j] = \left(\frac{PHy_i[j] + 1}{PHx_i[j] + 1} \right)^{0,2}$$

avec $PHx_i[j]$ et $PHy_i[j]$ comme puissances des signaux source et codé (après filtrage par le système IRS et l'addition du bruit de Hoth), respectivement dans la trame i et dans la bande j . Lorsque $PHx_i[j]$ et $PHy_i[j]$ ont une valeur inférieure à 20 dB au-dessus du seuil absolu d'audibilité dans la bande j (c'est-à-dire si $PHx_i[j]$ et $PHy_i[j]$ ont une valeur inférieure à $100 \cdot P_0[j]$), la composante $C_i[j]$ est mise à égalité avec 1. La valeur maximale de $C_i[j]$ a une limite supérieure de 2,0.

9.5.4 Traitement du bruit perturbateur, y compris les intervalles de silence

Dans la méthode PSQM, les intervalles de silence sont pris en compte au moyen d'un facteur de pondération, W_{sil} , qui dépend du contexte des expériences subjectives. Les trames de silence sont définies comme étant celles pour lesquelles le signal de source a une puissance totale de Px'_i (c'est-à-dire $\sum_j Px'_i[j]$) au-dessous du niveau acoustique de 70 dB. Si le facteur d'étalonnage global, S_p , a été calculé correctement, le seuil de silence est $Px'_i = 1,0 \cdot 10^7$. Les trames avec une puissance Px'_i au-dessous de cette valeur sont considérées comme étant silencieuses.

Les sonies moyennes du bruit, N_{spav} et N_{silav} , peuvent maintenant être calculées sur les trames de conversation active et sur les trames de silence, respectivement:

$$N_{spav} = \frac{1}{M_{sp}} \sum_{i \text{ pour les trames de conversation active}} N_i$$

$$N_{silav} = \frac{1}{M_{sil}} \sum_{i \text{ pour les trames de silence}} N_i$$

où M_{sp} est le nombre de trames de conversation actives et où M_{sil} est le nombre de trames de silence.

L'influence des intervalles de silence dépend directement de la longueur de ces intervalles. Si le signal vocal de source ne contient pas d'intervalles de silence, l'influence est nulle. Si le signal vocal de source contient un certain pourcentage de trames de silence, l'influence est proportionnelle à ce pourcentage. En utilisant un ensemble de conditions aux limites triviales, on peut montrer que la pondération correcte est la suivante:

$$N_{wsil} = \frac{W_{sp} \cdot p_{sp}}{W_{sp} \cdot p_{sp} + p_{sil}} \cdot N_{spav} + \frac{p_{sil}}{W_{sp} \cdot p_{sp} + p_{sil}} \cdot N_{silav}$$

où p_{sil} est la fraction de trames de silence, p_{sp} la fraction de trames de conversation actives ($p_{sil} + p_{sp} = 1,0$), où W_{sil} est le facteur de pondération sur les intervalles de silence, où $W_{sp} = \frac{1 - W_{sil}}{W_{sil}}$, et où N_{wsil} est le bruit perturbateur corrigé par le facteur de pondération W_{sil} pour l'intervalle de silence.

Ce bruit perturbateur N_{wsil} , appelé *valeur PSQM* dans les paragraphes suivants, peut être utilisé pour prédire la qualité de parole perçue subjectivement, obtenue par la méthode d'évaluation par catégories absolues (ACR) avec l'échelle de qualité d'écoute.

NOTES

1 La valeur de la pondération N_{wsil} doit avoir une limite supérieure de 6,5

2 Pour le matériel vocal comportant de longues périodes de silence, la pondération est différente de celle du matériel vocal comportant seulement de courtes périodes de silence. Par ailleurs, le bruit affectant l'enregistrement du matériel de source exerce également une influence sur la pondération de l'intervalle de silence. Pour le matériel vocal ne comportant pas d'intervalles de silence, la pondération n'est pas applicable et le terme N_{wsil} devient égal à N_{spav} . Un certain nombre de bases de données vocales ont été examinées afin de déterminer la pondération optimale sur les intervalles de silence. Ces bases de données se composaient de matériel vocal avec environ 50% d'intervalles de silence. La pondération optimale qui a été trouvée variait entre 0,0 et 0,5 [10] [11] [12]. La détermination de la valeur de W_{sil} pour les paroles avec intervalles de silence est encore à l'étude. Un facteur de pondération de 0,2 est provisoirement recommandé pour le matériel vocal comportant environ 50% d'intervalles de silence.

10 Transformation de l'échelle de qualité objective en échelle de qualité subjective

La sortie de l'algorithme décrit dans l'article 9, appelé *valeur PSQM*, indique le degré de dégradation de la qualité subjective en raison du codage de la parole. Lorsque l'estimation de la qualité subjective sur une échelle spécifique n'est pas nécessaire, par exemple lors de l'optimisation des paramètres d'un codec ou lors de la simple comparaison des performances de codecs, la valeur de mesure PSQM est donc très utile par elle-même. Pour estimer la qualité subjective sur des échelles d'évaluation telles que les notes moyennes d'opinion (MOS) et notes Q équivalentes, la mesure PSQM est cependant transformée comme décrit ci-dessous.

10.1 Notes moyennes d'opinion

Lors de l'évaluation subjective de la performance des codecs, la méthode d'évaluation ACR, faisant appel à l'échelle de qualité d'écoute spécifiée dans la Recommandation P.800 est souvent utilisée; elle exprime la qualité subjective en notes MOS. Etant donné que la relation entre notes MOS et mesures PSQM n'est pas nécessairement la même selon les différentes langues, il est difficile de déterminer une fonction unique permettant de transformer la valeur PSQM en valeur MOS estimée. En pratique, il est donc nécessaire de calculer d'avance de telles fonctions de transformation pour chaque langue et pour chaque essai subjectif particulier.

NOTE – La valeur absolue de la note MOS dépend du contexte de l'expérience subjective. La note MOS estimée qui est obtenue par une fonction de transformation prédéterminée prédit la qualité subjective perçue lors de l'expérience subjective avec un contexte équivalent à celui qui a été utilisé pour calculer la fonction de transformation.

Lorsque les résultats sont présentés dans le domaine des notes MOS estimées, il convient d'inclure dans le rapport la fonction de transformation entre la valeur PSQM et la valeur MOS.

10.2 Notes Q équivalentes

Il est difficile de comparer les notes MOS obtenues lors de différentes expériences subjectives car le jugement subjectif est affecté par les conditions d'expérience, par exemple l'étendue de l'échelle de qualité vocale utilisé dans l'expérience. Les valeurs Q équivalentes sont donc utilisées parfois comme échelle de qualité subjective. Ce sont les valeurs Q de l'appareil MNRU qui est défini dans la Recommandation P.810, pour lequel les notes MOS sont équivalentes à celles du signal vocal codé.

Dans la mesure objective, la valeur Q équivalente peut être estimée directement à partir des valeurs de la mesure PSQM pour le signal vocal codé et les conditions de l'appareil MNRU, sans transformation de la valeur PSQM en note MOS (voir la Figure 4). Lorsque les résultats sont présentés dans le domaine des valeurs Q équivalentes estimées, il y a lieu d'inclure dans le rapport la courbe des valeurs Q en fonction des valeurs PSQM, illustrée dans la Figure 4.

NOTE - Les valeurs Q équivalentes deviennent relativement peu fiables dans les régions haute et basse de leur répartition, parce que la courbe des valeurs Q en fonction des mesures PSQM devient presque plate dans ces régions. En conséquence, il convient de prendre des précautions lorsque l'on travaille dans le domaine Q avec des signaux vocaux de très haute ou de très basse qualité.




FIGURE 4/P.861

Détermination de la valeur Q équivalente du signal vocal codé

11 Analyse des résultats

L'analyse des résultats des mesures objectives doit être effectuée sur la base des valeurs PSQM, des notes MOS estimées ou des valeur Q équivalentes estimées.

Pour chaque condition d'essai, il convient de calculer et de rapporter séparément les notes moyennes correspondant aux locuteurs et aux locutrices, ainsi que leur moyenne générale.

Le calcul d'un écart type distinct pour chaque condition d'essai n'est pas recommandé. Les limites de confiances doivent être évaluées par prise en compte de la variation de qualité objective selon les locuteurs, selon les phrases et selon les tests de signification effectués par des techniques conventionnelles d'analyse de variance.

NOTE – L'analyse statistique décrite ici est différente de celle qui est effectuée lors des évaluations subjectives où les moyennes de qualité subjective sont statistiquement évaluées par prise en compte des variations selon les sujets, les locuteurs et les phrases. Etant donné que la mesure PSQM ne peut pas donner une estimation des distributions des votes subjectifs mais qu'elle n'indique que leur valeur moyenne, il est impossible d'effectuer l'analyse selon les sujets. L'estimation des courbes de répartition des votes subjectifs est encore à l'étude. Lorsqu'une analyse selon les sujets sera nécessaire, il conviendra donc d'effectuer des expériences subjectives conformes à la Recommandation P.830.

Bibliographie

- [1] NTT: Transmission performance objective evaluation model for fundamental factors, *CCITT Contribution COM XII-174*, novembre 1983.
- [2] LALOU (J.): L'indice d'information: mesure objective de la qualité de transmission de la parole - *Annales des Télécommunications*, Volume 45, n° 1-2, p. 47-65, CNET/France, 1990.
- [3] BNR: Evaluation of non-linear distortion via the coherence function, *CCITT Contribution COM XII-60*, avril 1982.

- [4] KUBICHEK (R.F.), QUINCY (E.A.), KISER (K.L.): Speech Quality Assessment Using Expert Pattern Recognition Techniques, *Proceedings of the IEEE Pacific Rim Conference on Computers, Communication, and Signal Processing*, juin 1989.
- [5] Royal PTT, Netherlands: Measuring the quality of audio devices, *CCITT Contribution COM XII-114*, Genève, décembre 1991.
- [6] BEERENDS (J.G.), STEMERDINK (J.A.): A Perceptual Speech-Quality Measure Based on a Psychoacoustic Sound Representation, *J. Audio Eng. Soc.*, Vol. 42, n° 3, p. 115-123, mars 1994.
- [7] BEERENDS (J.G.): Modelling Cognitive Effects that Play a Role in the Perception of Speech Quality, *Speech Quality Assessment*, Workshop papers, Bochum, p. 1-9, novembre 1994.
- [8] Supplément n° 13 du CCITT aux Recommandations de la série P, *Spectres de bruit*, article 2, Livre bleu, tome V, UIT, Genève, 1988.
- [9] ZWICKER (Feldtkeller): *Das Ohr als Nachrichtenempfänger*, S. Hirzel Verlag, Stuttgart, 1967.
- [10] Royal PTT, The Netherlands: Correlation of a perceptual quality speech measure with the subjective quality of the CCITT LD-CELP (G.728) speech codec, *ITU-T Contribution COM 12-10*, Genève, mars 1993.
- [11] Royal PTT, The Netherlands: Correlation between the PSQM and the subjective results of ITU-T 8 kbit/s 1993 speech codec test, *ITU-T Contribution COM 12-31*, Genève, septembre 1994.
- [12] NTT: Review of validation tests for objective speech quality measures, *ITU-T Contribution COM 12-74*, Genève, mai 1996.
- [13] PRESS (W.H.) *et al.*: *Numerical Recipes in C, The Art of Scientific Computing*, Cambridge University Press, Cambridge, Massachusetts, 1988.

Appendice I

Contenu de la disquette accompagnant la Recommandation P.861

I.1 Introduction

Une disquette a été insérée dans la présente Recommandation afin d'aider ses lecteurs à réaliser leurs propres mesures PSQM. Le présent appendice en décrit les fichiers.

I.2 Répertoire\src

Ce répertoire contient un exemple de rédaction en code "C" de l'algorithme décrit dans cette Recommandation. Ce code est conçu pour exploiter des fichiers de parole codés en mots MIC linéaires de 16 bits, échantillonnés à 16 kHz et enregistrés avec l'octet de poids faible (LSB, *least significant bit*) placé en premier. Les fichiers suivants sont inclus dans ce répertoire:

psqm.c	psqm.h	psqmprot.h
psqmvals.c	readsamp.c	spchopn.c
spchread.c		

Le contenu de ces fichiers est décrit ci-dessous:

<code>psqm.c</code>	Ce fichier contient l'essentiel des instructions logiques pour le calcul de la mesure PSQM. L'algorithme de transformée de Fourier rapide FFT utilisé n'a pas été inclus en raison de restrictions de copyright. Cet algorithme avait été extrait de l'ouvrage suivant: <i>Numerical Recipes in C</i> (Press, W.H. et al. [1988], <i>Numerical Recipes in C, The Art of Scientific Computing</i> , Cambridge University Press, Cambridge, Massachusetts.)
<code>psqm.h</code>	Ce fichier contient les déclarations des variables disponibles globalement pour le calcul de la mesure PSQM.
<code>Psqmprot.h</code>	Ce fichier contient les prototypes fonctionnels pour toutes les fonctions utilisées dans le calcul de la mesure PSQM.
<code>Psqmvals.c</code>	Ce fichier contient les affectations de valeur pour les constantes et pour les tables numériques utilisées dans le calcul de la mesure PSQM.
<code>Readsamp.c</code>	Ce fichier contient la fonction de lecture des entiers échantillonnés. Cette fonction effectue la lecture trame par trame du signal vocal pour traitement.
<code>Spchopn.c</code>	Ce fichier contient une fonction qui ouvre le fichier de signaux vocaux et détermine les points de départ et d'arrêt sur la base de l'algorithme décrit dans 9.1.1/P.861.
<code>spchread.c</code>	Ce fichier contient la fonction de lecture des entiers du fichier de signaux vocaux. Elle sert d'interface avec la fonction de lecture des échantillons.

I.3 Répertoire\test

Ce répertoire contient des fichiers servant aux tests de précision d'une mise en oeuvre de la mesure PSQM. Les fichiers contenus dans ce répertoire sont les suivants:

<code>longs.cod</code>	<code>longs.src</code>	<code>outlong.txt</code>
<code>outshort.txt</code>	<code>shorts.cod</code>	<code>shorts.src</code>

Le contenu de ces fichiers est décrit ci-dessous.

<code>longs.cod</code>	Fichier de signaux vocaux codés qui est destiné à servir lors de l'étalonnage de la mesure PSQM. Octet de poids faible enregistré en premier et retard de 22 échantillons par rapport au fichier source de signaux vocaux.
<code>longs.src</code>	Fichier source de signaux vocaux utilisé pour créer le fichier <code>longs.cod</code> . Octet LSB enregistré en premier.
<code>Outlong.txt</code>	Signal de sortie trame par trame pour le vecteur d'essai de longue durée. En plus des variables d'étalonnage (S_p et S_l), ce fichier contient les informations suivantes: facteur de normalisation global calculé (S_{global}); points de départ et d'arrêt pour les deux fichiers de signaux vocaux, source et codé; bruit perturbateur trame par trame (N_i); indicateur trame par trame de trame silencieuse (1=silence, 0 bruit).

Outshort.txt	<p>Valeurs pas à pas des variables pour le vecteur d'essai de courte durée. Ce fichier nécessite la configuration des valeurs suivantes dans le programme:</p> <p>retard = 0</p> <p>point de départ = 0</p> <p>point d'arrêt = 511</p> <p>facteur de normalisation $S_{global} = 1,0$</p> <p>Les valeurs intermédiaires suivantes sont fournies dans le fichier:</p> <p>séquence d'entrée ($x_i[n], y_i[n]$)</p> <p>version fenêtrée de la séquence d'entrée ($xw_i[n], yw_i[n]$)</p> <p>échantillons de densité de puissance spectrale ($Px_i[k], Py_i[k]$)</p> <p>facteur de normalisation locale (S_i)</p> <p>échantillons de densité de puissance fondamentale ($Px'_i[j], Py'_i[j]$)</p> <p>résultats du filtrage en bande téléphonique ($PFx_i[j], PFy_i[j]$)</p> <p>résultats d'injection du bruit de Hoth ($PHx_i[j], PHy_i[j]$)</p> <p>échantillons de densité de sonie comprimée ($Lx_i[j], Ly_i[j]$)</p> <p>facteur de normalisation locale de la sonie (Sl_i)</p> <p>échantillons de densité du bruit perturbateur ($N_i[j]$)</p> <p>facteur d'influence de l'asymétrie ($C_i[j]$)</p> <p>bruit perturbateur (N_i)</p>
shorts.cod	Fichier de signaux vocaux codés destinés à servir lors de l'étalonnage de la mesure PSQM. Octet LSB en premier et retardé de 0 échantillon par rapport au fichier vocal source.
shorts.src	Fichier vocal source utilisé pour créer le fichier shorts.cod. Octet LSB en premier.

SÉRIES DES RECOMMANDATIONS UIT-T

- Série A Organisation du travail de l'UIT-T
- Série B Moyens d'expression
- Série C Statistiques générales des télécommunications
- Série D Principes généraux de tarification
- Série E Réseau téléphonique et RNIS
- Série F Services de télécommunication non téléphoniques
- Série G Systèmes et supports de transmission
- Série H Transmission des signaux autres que téléphoniques
- Série I Réseau numérique à intégration de services
- Série J Transmission des signaux radiophoniques et télévisuels
- Série K Protection contre les perturbations
- Série L Construction, installation et protection des câbles et autres éléments des installations extérieures
- Série M Maintenance: systèmes de transmission, de télégraphie, de télécopie, circuits téléphoniques, et circuits loués internationaux
- Série N Maintenance: circuits internationaux de transmission radiophoniques et télévisuels
- Série O Spécifications des appareils de mesure
- Série P Qualité de transmission téléphonique**
- Série Q Commutation et signalisation
- Série R Transmission télégraphique
- Série S Equipements terminaux de télégraphie
- Série T Equipements terminaux et protocoles des services télématiques
- Série U Commutation télégraphique
- Série V Communications de données sur le réseau téléphonique
- Série X Réseaux pour données et communication entre systèmes ouverts
- Série Z Langages de programmation



* 9 7 5 0 *

Imprimé en Suisse
Genève, 1997