


NORME
INTERNATIONALE
INTERNATIONAL
STANDARD

**CEI
IEC
559**

Deuxième édition
Second edition
1989-01

**Arithmétique binaire en virgule flottante
pour systèmes à microprocesseurs**

**Binary floating-point arithmetic
for microprocessor systems**



Numéro de référence
Reference number
CEI/IEC 559: 1989

Révision de la présente publication

Le contenu technique des publications de la CEI est constamment revu par la Commission afin d'assurer qu'il reflète bien l'état actuel de la technique.

Les renseignements relatifs à ce travail de révision, à l'établissement des éditions révisées et aux mises à jour peuvent être obtenus auprès des Comités nationaux de la CEI et en consultant les documents ci-dessous:

- **Bulletin de la CEI**
- **Annuaire de la CEI**
- **Catalogue des publications de la CEI**
Publié annuellement

Terminologie

En ce qui concerne la terminologie générale, le lecteur se reportera à la Publication 50 de la CEI: Vocabulaire Electrotechnique International (VEI), qui est établie sous forme de chapitres séparés traitant chacun d'un sujet défini, l'Index général étant publié séparément. Des détails complets sur le VEI peuvent être obtenus sur demande.

Les termes et définitions figurant dans la présente publication ont été soit repris du VEI, soit spécifiquement approuvés aux fins de cette publication.

Symboles graphiques et littéraires

Pour les symboles graphiques, symboles littéraires et signes d'usage général approuvés par la CEI, le lecteur consultera:

- la Publication 27 de la CEI: Symboles littéraires à utiliser en électrotechnique;
- la Publication 617 de la CEI: Symboles graphiques pour schémas.

Les symboles et signes contenus dans la présente publication ont été soit repris des Publications 27 ou 617 de la CEI, soit spécifiquement approuvés aux fins de cette publication.

Publications de la CEI établies par le même Comité d'Etudes

L'attention du lecteur est attirée sur le deuxième feuillet de la couverture, qui énumère les publications de la CEI préparées par le Comité d'Etudes qui a établi la présente publication.

Revision of this publication

The technical content of IEC publications is kept under constant review by the IEC, thus ensuring that the content reflects current technology.

Information on the work of revision, the issue of revised editions and amendment sheets may be obtained from IEC National Committees and from the following IEC sources:

- **IEC Bulletin**
- **IEC Yearbook**
- **Catalogue of IEC Publications**
Published yearly

Terminology

For general terminology, readers are referred to IEC Publication 50: International Electrotechnical Vocabulary (IEV), which is issued in the form of separate chapters each dealing with a specific field, the General Index being published as a separate booklet. Full details of the IEV will be supplied on request.

The terms and definitions contained in the present publication have either been taken from the IEV or have been specifically approved for the purpose of this publication.

Graphical and letter symbols

For graphical symbols, and letter symbols and signs approved by the IEC for general use, readers are referred to:

- IEC Publication 27: Letter symbols to be used in electrical technology;
- IEC Publication 617: Graphical symbols for diagrams.

The symbols and signs contained in the present publication have either been taken from IEC Publications 27 or 617, or have been specifically approved for the purpose of this publication.

IEC publications prepared by the same Technical Committee

The attention of readers is drawn to the back cover, which lists IEC publications issued by the Technical Committee which has prepared the present publication.

NORME
INTERNATIONALE
INTERNATIONAL
STANDARD

CEI
IEC
559

Deuxième édition
Second edition
1989-01

**Arithmétique binaire en virgule flottante
pour systèmes à microprocesseurs**

**Binary floating-point arithmetic
for microprocessor systems**

© CEI 1989 Droits de reproduction réservés — Copyright — all rights reserved

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'éditeur.

No part of this publication may be reproduced or utilized in any form or by any means, electronic or mechanical, including photocopying and microfilm, without permission in writing from the publisher.

Bureau Central de la Commission Electrotechnique Internationale 3, rue de Varembe Genève, Suisse



Commission Electrotechnique Internationale
International Electrotechnical Commission
Международная Электротехническая Комиссия

CODE PRIX
PRICE CODE

18

Pour prix, voir catalogue en vigueur
For price, see current catalogue

SOMMAIRE

	Pages
PREAMBULE	4
PREFACE	4
Articles	
1. Domaine d'application	6
1.1 Objectifs de réalisation	6
1.2 Inclusions	6
1.3 Exclusions	6
2. Définitions	6
3. Formats	10
3.1 Ensembles de valeurs	12
3.2 Formats de base	14
3.3 Formats étendus	16
3.4 Combinaisons de formats	16
4. Arrondi	18
4.1 Arrondi au plus près	18
4.2 Arrondis orientés	18
4.3 Précision d'arrondi	18
5. Opérations	20
5.1 Arithmétique	20
5.2 Racine carrée	22
5.3 Conversions des formats virgule flottante	22
5.4 Conversion entre virgule flottante et entier	22
5.5 Arrondi de nombres en virgule flottante vers une valeur entière	22
5.6 Conversion binaire-décimale	22
5.7 Comparaison	26
6. Infini, non-nombres et zéro signé	30
6.1 Arithmétique de l'infini	30
6.2 Opérations avec des non-nombres	30
6.3 Bit de signe	32
7. Exceptions	32
7.1 Opérations invalides	32
7.2 Division par zéro	34
7.3 Dépassement de capacité	34
7.4 Dépassement de capacité inférieur	36
7.5 Inexactitude	38
8. Déroutements	38
8.1 Routine de traitement de déroutement	40
8.2 Précédence	40
ANNEXE A - Fonctions et prédicats recommandés	42

CONTENTS

	Page
FOREWORD	5
PREFACE	5
Clause	
1. Scope	7
1.1 Implementation objectives	7
1.2 Inclusions	7
1.3 Exclusions	7
2. Definitions	7
3. Formats	11
3.1 Sets of values	13
3.2 Basic formats	15
3.3 Extended formats	17
3.4 Combinations of formats	17
4. Rounding	19
4.1 Round to nearest	19
4.2 Directed roundings	19
4.3 Rounding precision	19
5. Operations	21
5.1 Arithmetic	21
5.2 Square root	23
5.3 Floating-point format conversions	23
5.4 Conversions between floating-point and integer	23
5.5 Round floating-point number to integral value	23
5.6 Binary $\leftrightarrow$ decimal conversion	23
5.7 Comparison	27
6. Infinity, NaNs and signed zero	31
6.1 Infinity arithmetic	31
6.2 Operations with NaNs	31
6.3 The sign bit	33
7. Exceptions	33
7.1 Invalid operations	33
7.2 Division by zero	35
7.3 Overflow	35
7.4 Underflow	37
7.5 Inexact	39
8. Traps	39
8.1 Trap handler	41
8.2 Precedence	41
APPENDIX A - Recommended functions and predicates	43

COMMISSION ELECTROTECHNIQUE INTERNATIONALE

ARITHMETIQUE BINAIRE EN VIRGULE FLOTTANTE
POUR SYSTEMES A MICROPROCESSEURS

PREAMBULE

- 1) Les décisions ou accords officiels de la CEI en ce qui concerne les questions techniques, préparés par des Comités d'Etudes où sont représentés tous les Comités nationaux s'intéressant à ces questions, expriment dans la plus grande mesure possible un accord international sur les sujets examinés.
- 2) Ces décisions constituent des recommandations internationales et sont agréées comme telles par les Comités nationaux.
- 3) Dans le but d'encourager l'unification internationale, la CEI exprime le vœu que tous les Comités nationaux adoptent dans leurs règles nationales le texte de la recommandation de la CEI, dans la mesure où les conditions nationales le permettent. Toute divergence entre la recommandation de la CEI et la règle nationale correspondante doit, dans la mesure du possible, être indiquée en termes clairs dans cette dernière.

PREFACE

La présente norme a été établie par le Sous-Comité 47B: Systèmes à microprocesseurs, du Comité d'Etudes n° 47 de la CEI: Dispositifs à semiconducteurs. (Ce Sous-Comité a été repris par l'ISO/IEC JTC 1.)

Cette deuxième édition de la Publication 559 remplace la première édition parue en 1982.

Le texte de cette norme est issu des documents suivants:

Règle des Six Mois	Rapport de vote
47B(BC)19	47B(BC)26

Le rapport de vote indiqué dans le tableau ci-dessus donne toute information sur le vote ayant abouti à l'approbation de cette norme.

INTERNATIONAL ELECTROTECHNICAL COMMISSION

BINARY FLOATING-POINT ARITHMETIC
FOR MICROPROCESSOR SYSTEMS

FOREWORD

- 1) The formal decisions or agreements of the IEC on technical matters, prepared by Technical Committees on which all the National Committees having a special interest therein are represented, express, as nearly as possible, an international consensus of opinion on the subjects dealt with.
- 2) They have the form of recommendations for international use and they are accepted by the National Committees in that sense.
- 3) In order to promote international unification, the IEC expresses the wish that all National Committees should adopt the text of the IEC recommendation for their national rules in so far as national conditions will permit. Any divergence between the IEC recommendation and the corresponding national rules should, as far as possible, be clearly indicated in the latter.

PREFACE

This standard has been prepared by Sub-Committee 47B: Microprocessor systems, of IEC Technical Committee No. 47: Semiconductor devices. (This Sub-Committee has been taken over by ISO/IEC JTC 1.)

This second edition of IEC Publication 559 replaces the first edition issued in 1982.

The text of this standard is based on the following documents:

Six Months' Rule	Report on Voting
47B(C0)19	47B(C0)26

Full information on the voting for the approval of this standard can be found in the Voting Report indicated in the above table.

ARITHMETIQUE BINAIRE EN VIRGULE FLOTTANTE POUR SYSTEMES A MICROPROCESSEURS

1. Domaine d'application

1.1 Objectifs de réalisation

L'objectif est qu'une réalisation d'un système à virgule flottante conforme à la présente norme puisse être effectuée entièrement par logiciel, entièrement par matériel, ou par une combinaison quelconque de logiciel et de matériel. C'est l'environnement que le programmeur ou l'utilisateur voit qui est conforme ou non conforme à cette norme. Les composants matériels qui nécessitent un support logiciel pour devenir conformes ne doivent pas être qualifiés de conformes indépendamment d'un tel logiciel.

1.2 Inclusions

Cette norme spécifie:

- 1) les formats de base et étendu des nombres en virgule flottante;
- 2) les opérations d'addition, de soustraction, de multiplication, de division, de calcul d'une racine carrée, du calcul d'un reste et de comparaison;
- 3) les conversions entre nombres entiers et nombres en virgule flottante;
- 4) les conversions entre différents formats en virgule flottante;
- 5) les conversions entre les nombres en virgule flottante en format de base et les chaînes décimales, et
- 6) la détection et le traitement des conditions d'exception pour les nombres en virgule flottante y compris les non-nombres ("NaN").

1.3 Exclusions

Cette norme ne spécifie pas:

- 1) les formats des chaînes décimales et des entiers;
- 2) l'interprétation des champs de signe et de mantisse des non-nombres ("NaN"), ou
- 3) les conversions de binaire à décimal et réciproquement pour les formats étendus.

2. Définitions

Exposant avec excédent

Somme de l'exposant et d'une constante (excédent ou biais) choisie de manière à rendre non négatif le domaine de l'exposant avec excédent.

BINARY FLOATING-POINT ARITHMETIC FOR MICROPROCESSOR SYSTEMS

1. Scope

1.1 *Implementation objectives*

It is intended that an implementation of a floating-point system conforming to this standard can be realized entirely in software, entirely in hardware, or in any combination of software and hardware. It is the environment that the programmer or user of the system sees that conforms or fails to conform to this standard. Hardware components that require software support to conform shall not be said to conform apart from such software.

1.2 *Inclusions*

This standard specifies:

- 1) basic and extended floating-point number formats;
- 2) add, subtract, multiply, divide, square root, remainder and compare operations;
- 3) conversions between integer and floating-point numbers;
- 4) conversions between different floating-point formats;
- 5) conversions between basic format floating-point numbers and decimal strings, and
- 6) floating-point exceptions and their handling, including non-numbers (NaNs).

1.3 *Exclusions*

This standard does not specify:

- 1) formats of decimal strings and integers;
- 2) interpretation of the signs and significant fields of NaNs, or
- 3) binary $\leftrightarrow$ decimal conversions to and from extended formats.

2. Definitions

Biased exponent

The sum of the exponent and a constant (bias) chosen to make the biased exponent's range non-negative.

Nombre binaire en virgule flottante

Chaîne de bits caractérisée par trois éléments: un signe, un exposant signé et une mantisse. Sa valeur numérique, si elle existe, est le produit signé de sa mantisse par deux élevé à la puissance de son exposant. Dans la présente norme, une chaîne de bits n'est pas toujours distinguée du nombre qu'elle représente.

Nombre dénormalisé

Nombre en virgule flottante non nul dont l'exposant a une valeur réservée, d'habitude la valeur minimale du format et dont le bit significatif de la mantisse, explicite ou implicite, est nul.

Destination

Emplacement devant contenir le résultat d'une opération binaire ou unaire. La destination peut être soit désignée explicitement par l'utilisateur ou fournie de manière implicite par le système (pour les résultats intermédiaires dans les sous-expressions ou les arguments de procédures par exemple). Certains langages placent les résultats des calculs intermédiaires dans des emplacements non accessibles par l'utilisateur. Néanmoins, cette norme définit le résultat d'une opération en termes du format de cette destination aussi bien que des valeurs des opérandes.

Exposant

Élément d'un nombre binaire en virgule flottante qui représente normalement la puissance entière à laquelle deux est élevé pour déterminer la valeur du nombre représenté. Occasionnellement, l'exposant est appelé exposant signé ou exposant sans excédent.

Partie fractionnaire

Partie de la mantisse située à droite de sa virgule correspondante.

Mode

Variable qu'un utilisateur peut positionner, tester, sauvegarder et restaurer pour diriger l'exécution des opérations arithmétiques ultérieures. Le mode par défaut est le mode valable tant qu'une instruction contraire explicite n'est pas incluse dans le programme ou sa spécification.

Les modes suivants doivent être mis en place:

- 1) arrondi, pour commander la direction des erreurs d'arrondi, et dans certaines réalisations;
- 2) précision de l'arrondi, pour diminuer la précision des résultats. Le réalisateur peut fournir optionnellement les modes suivants:
- 3) déroutements désactivés/activés, pour gérer les conditions d'exception.

Binary floating-point number

A bit-string characterized by three components: a sign, a signed exponent, and a significand. Its numerical value, if any, is the signed product of its significand and two raised to the power of its exponent. In this standard a bit-string is not always distinguished from a number it may represent.

Denormalized number

A nonzero floating-point number, the exponent of which has a reserved value, usually the format's minimum, and the explicit or implicit leading significant bit of which is zero.

Destination

The location for the result of a binary or unary operation. The destination may be either explicitly designated by the user or implicitly supplied by the system (e.g. intermediate results in sub-expressions or arguments for procedures). Some languages place the results of intermediate calculations in destinations beyond the user's control. Nonetheless, this standard defines the result of an operation in terms of that destination's format as well as the operands' values.

Exponent

The component of a binary floating-point number that normally signifies the integer power to which two is raised in determining the value of the represented number. Occasionally the exponent is called the signed or unbiased exponent.

Fraction

The field of the significand that lies to the right of its implied binary point.

Mode

A variable that a user may set, sense, save and restore, to control the execution of subsequent arithmetic operations. The default mode is the mode that a program can assume to be in effect unless an explicitly contrary statement is included either in the program or in its specification.

The following modes shall be implemented:

- 1) rounding, to control the direction of rounding errors, and in certain implementations.
- 2) rounding precision, to shorten the precision of results. The implementor may, at his option, implement the following modes:
- 3) traps disabled/enabled, to handle exceptions.

NaN (non-nombre)

Non-nombre; entité symbolique codée selon le format virgule flottante. Il existe deux types de non-nombres (voir 6.2). Les non-nombres indicateurs indiquent une condition d'exception concernant une opération invalide (voir 7.1) lorsqu'ils apparaissent en tant qu'opérandes. Les non-nombres muets se propagent à travers presque toutes les opérations arithmétiques sans signaler d'exceptions.

Résultat

Chaîne de bits (représentant généralement un nombre) qui est livrée à la destination.

Mantisse

Élément d'un nombre binaire en virgule flottante constituée d'un bit significatif explicite ou implicite placé à gauche de la virgule et d'un champ fractionnaire à droite de la virgule.

Doit

Le mot "doit" recouvre les parties obligatoires de toute réalisation conforme.

Il convient - Il est recommandé - Il y a lieu

Ces termes recouvrent les parties qui sont fortement recommandées comme étant dans l'esprit de cette norme, bien que des contraintes architecturales ou autres, hors du domaine de cette norme, puissent à l'occasion rendre ces recommandations peu pratiques.

Indicateur d'état

Variable qui peut prendre deux états, actif (valeur 1) ou inactif (valeur 0). Un utilisateur peut désactiver un indicateur, le copier, ou le remettre dans un état antérieur. Lorsqu'il est actif, un indicateur peut contenir des informations supplémentaires dépendant du système et éventuellement inaccessibles à certains utilisateurs. Les opérations définies par cette norme peuvent avoir comme effet secondaire l'activation de certains des indicateurs suivants: résultat inexact, dépassement de capacité inférieur, dépassement de capacité supérieur, division par zéro et opération invalide.

Utilisateur

Toute personne, tout matériel ou logiciel non spécifié lui-même dans cette norme, ayant accès aux opérations de l'environnement de programmation spécifiées dans cette norme et qui les commande.

3. Formats

Cette norme définit quatre formats de virgule flottante en deux groupes, de base et étendu, chacun admettant deux largeurs, simple et double précision. Les niveaux de réalisation standard se distinguent par les combinaisons de formats supportés.

NaN

Not a number; a symbolic entity encoded in floating-point format. There are two types of NaNs (see 6.2). Signalling NaNs signal the invalid operation exception (see 7.1) whenever they appear as operands. Quiet NaNs propagate through almost every arithmetic operation without signalling exceptions.

Result

The bit-string (usually representing a number) that is delivered to the destination.

Significant

The component of a binary floating-point number which consists of an explicit or implicit leading bit to the left of its implied binary point and a fraction field to the right.

Shall

The word "shall" signifies that which is obligatory in any conforming implementation.

Should

The word "should" signifies that which is strongly recommended as being in keeping with the intent of the standard, although architectural or other constraints beyond the scope of this standard may, on occasion, render the recommendations impractical.

Status flag

A variable that may take two states, set and clear. A user may clear a flag, copy it, or restore it to a previous state. When set, a status flag may contain additional system-dependent information, possibly inaccessible to some users. The operations of this standard may, as a side-effect, set some of the following flags: inexact result, underflow, overflow, divide by zero and invalid operation.

User

Any person, hardware, or program not itself specified by this standard, having access to and controlling those operations of the programming environment specified in this standard.

3. Formats

This standard defines four floating-point formats in two groups, basic and extended, each having two widths, single and double. The standard levels of implementation are distinguished by the combinations of formats supported.

3.1 Ensembles de valeurs

Ce paragraphe concerne seulement les valeurs numériques représentables dans un format, et non leur codage qui fait l'objet des paragraphes suivants. Les seules valeurs représentables dans un format donné sont celles qui sont spécifiées selon les trois paramètres entiers suivants:

P = nombre de bits significatifs (précision)

$E_{\max}$ = valeur maximale de l'exposant, et

$E_{\min}$ = valeur minimale de l'exposant

Les paramètres de chaque format sont regroupés dans le tableau 1. Pour chaque format, les seules entités qui doivent être fournies sont:

Nombres de la forme $(-1)^s 2^E (b_0 b_1 b_2 \dots b_{p-1})$

où:

s vaut 0 ou 1;

E est un entier compris entre $E_{\min}$ et $E_{\max}$ bornes incluses, et chaque b_i vaut 0 ou 1.

Deux valeurs infinies, $+\infty$ et $-\infty$;

au moins un non-nombre indicateur, et
au moins un non-nombre muet.

Tableau 1 - Résumé des paramètres du format

Paramètre	Format			
	Simple	Simple Etendu	Double	Double Etendu
P	24	≥ 32	53	≥ 64
$E_{\max}$	+127	$\geq +1\ 023$	+1 023	$\geq +16\ 383$
$E_{\min}$	-126	$\leq -1\ 022$	-1 022	$\leq -16\ 382$
Excédent de l'exposant	+127	Non spécifié	+1 023	Non spécifié
Largeur de l'exposant (bits)	8	≥ 11	11	≥ 15
Largeur du format (bits)	32	≥ 43	64	≥ 79

La description précédente énumère certaines valeurs de manière redondante, par exemple:

$$2^0(1.0) = 2^1(0.1) = 2^2(0.01) = \dots$$

Cependant, le codage de telles valeurs non nulles peut être redondant seulement pour les formats étendus (voir 3.3). Les valeurs non nulles de la forme $\pm 2^{E_{\min}} (0.b_1 b_2 \dots b_{p-1})$ sont appelées

3.1 Sets of values

This sub-clause concerns only the numerical values representable within a format, not the encodings which are the subject of the following sub-clauses. The only values representable in a chosen format are those specified via the following three integer parameters:

P = number of significant bits (precision)

$E_{\max}$ = maximum exponent, and

$E_{\min}$ = minimum exponent

Each format's parameters are displayed in Table 1. Within each format just the following entities shall be provided:

Numbers of the form $(-1)^s 2^E (b_0 b_1 b_2 \dots b_{p-1})$

where:

s is 0 or 1;

E is any integer between $E_{\min}$ and $E_{\max}$ inclusive, and each b_i is 0 or 1.

Two infinities, $+\infty$ and $-\infty$;
at least one signalling NaN, and
at least one quiet NaN.

Table 1 - Summary of format parameters

Parameter	Format			
	Single	Single Extended	Double	Double Extended
P	24	≥ 32	53	≥ 64
$E_{\max}$	+127	$\geq +1\ 023$	+1 023	$\geq +16\ 383$
$E_{\min}$	-126	$\leq -1\ 022$	-1 022	$\leq -16\ 382$
Exponent bias	+127	Unspecified	+1 023	Unspecified
Exponent width (bits)	8	≥ 11	11	≥ 15
Format width (bits)	32	≥ 43	64	≥ 79

The foregoing description enumerates some values redundantly, for example:

$$2^0(1.0) = 2^1(0.1) = 2^2(0.01) = \dots$$

However, the encodings of such nonzero values may be redundant only in extended formats (see 3.3). The nonzero values of the form $\pm 2^{E_{\min}} (0.b_1 b_2 \dots b_{p-1})$ are called denormalized. Reserved exponents

"dénormalisées". Des valeurs réservées d'exposants peuvent être utilisées pour coder les non-nombres, $\pm\infty$, ± 0 , et les nombres dénormalisés. Pour toute variable ayant la valeur zéro, le bit de signe s fournit un bit supplémentaire d'information. Bien que tous les formats aient des représentations distinctes pour $+0$ et -0 , les signes sont significatifs en certaines circonstances, comme la division par zéro, et non dans d'autres. Dans cette norme, 0 et ∞ sont écrits sans signe lorsque ce dernier n'a pas d'importance.

3.2 Formats de base

Les nombres en format simple et double précision se composent de trois champs:

un signe s de 1 bit,

un exposant avec excédent $e = E + \text{excédent}$, et


une partie fractionnaire $f = \cdot b_1 b_2 \dots b_{p-1}$.

Le domaine des valeurs de l'exposant sans excédent E doit inclure tout entier placé entre les bornes $E_{\min}$ et $E_{\max}$ incluses, ainsi que deux autres valeurs réservées: $E_{\min}-1$ pour coder ± 0 et les nombres dénormalisés, et $E_{\max}+1$ pour coder $\pm\infty$ et les non-nombres. Les paramètres ci-dessus apparaissent dans le tableau 1. Chaque valeur numérique non nulle possède un codage unique. Les champs sont interprétés comme suit:

3.2.1 Simple précision

Un nombre X de 32 bits en format simple précision est constitué comme indiqué sur la figure 1. La valeur v de X se déduit de ses champs constitutifs soit:

- 1) Si $e = 255$ et $f \neq 0$, alors v est un non-nombre quel que soit s
- 2) Si $e = 255$ et $f = 0$, alors $v = (-1)^s \infty$
- 3) Si $0 < e < 255$, alors $v = (-1)^s 2^{e-127} (1, f)$
- 4) Si $e = 0$ et $f \neq 0$, alors $v = (-1)^s 2^{-126} (0, f)$ (nombres dénormalisés)
- 5) Si $e = 0$ et $f = 0$, alors $v = (-1)^s 0$ (zéro)



"msb" représente le bit le plus significatif
 "lsb" représente le bit le moins significatif

Figure 1 - Format simple précision

may be used to encode NaNs, $\pm\infty$, ± 0 , and denormalized numbers. For any variable that has the value zero, the sign bit s provides an extra bit of information. Although all formats have distinct representations for $+0$, and -0 , the signs are significant in some circumstances, like division by zero, and not in others. In this standard 0 and ∞ are written without a sign when the sign does not matter.

3.2 Basic formats

Numbers in the single and double formats are composed of three fields:

a 1-bit sign s ,

a biased exponent $e = E + \text{bias}$, and


a fraction $f = \cdot b_1 b_2 \dots b_{p-1}$.

The range of the unbiased exponent E shall include every integer between two values $E_{\min}$ and $E_{\max}$ inclusive, and also two other reserved values: $E_{\min}-1$ to encode ± 0 and denormalized numbers, and $E_{\max}+1$ to encode $\pm\infty$ and NaNs. The foregoing parameters appear in Table 1. Each nonzero numerical value has just one encoding. The fields are interpreted as follows:

3.2.1 Single

A 32-bit single format number X is divided as shown in Figure 1. The value v of X is inferred from its constituent fields thus:

- 1) If $e = 255$ and $f \neq 0$, then v is a NaN regardless of s
- 2) If $e = 255$ and $f = 0$, then $v = (-1)^s \infty$
- 3) If $0 < e < 255$, then $v = (-1)^s 2^{e-127} (1.f)$
- 4) If $e = 0$ and $f \neq 0$, then $v = (-1)^s 2^{-126} (0.f)$ (denormalized numbers)
- 5) If $e = 0$ and $f = 0$, then $v = (-1)^s 0$ (zero)



"msb" means "most significant bit"

"lsb" means "least significant bit"

Figure 1 - Single format

3.2.2 Double précision

Un nombre X de 64 bits en format double précision est constitué comme indiqué sur la figure 2. La valeur v de X se déduit de ses champs constitutifs, soit:

- 1) Si $e = 2\ 047$ et $f \neq 0$, alors v est un non-nombre quel que soit s
- 2) Si $e = 2\ 047$ et $f = 0$, alors $v = (-1)^s \infty$
- 3) Si $0 < e < 2\ 047$, alors $v = (-1)^s 2^{e-1\ 023} (1, f)$
- 4) Si $e = 0$ et $f \neq 0$, alors $v = (-1)^s 2^{-1\ 022} (0, f)$ (nombres dénormalisés)
- 5) Si $e = 0$ et $f = 0$, alors $v = (-1)^s 0$ (zéro)




Figure 2 - Format double précision

3.3 Formats étendus

Les formats étendus simple précision et double précision assurent le codage de manière dépendante de la réalisation pour les ensembles de valeurs de 3.1, assujetties aux contraintes du tableau 1. Cette norme permet à une réalisation de coder certaines valeurs de manière redondante pourvu que cette redondance soit transparente à l'utilisateur selon le sens suivant: soit une réalisation doit coder chaque valeur non nulle de manière unique, soit elle ne doit faire aucune distinction entre les codages redondants des valeurs non nulles. Une réalisation peut également réserver quelques chaînes de bits pour des utilisations en dehors du domaine de cette norme; lorsqu'une telle chaîne de bits réservée est utilisée comme opérande, le résultat n'est pas spécifié par cette norme.

Une réalisation de cette norme n'est pas tenue de faire en sorte (et il y a lieu que l'utilisateur ne présume pas) que le format étendu simple précision possède un domaine plus grand que le format étendu double précision.

3.4 Combinaisons de formats

Toutes les réalisations conformes à cette norme doivent supporter le format simple précision. Il convient que les réalisations supportent le format étendu correspondant au format de base le plus grand qu'elles supportent et elles ne sont pas tenues de supporter d'autres formats étendus.*

* C'est seulement au cas où la compatibilité ascendante et la vitesse de calcul sont importantes qu'il convient qu'un système supportant le format étendu double précision supporte aussi le format étendu simple précision.

3.2.2 Double

A 64-bit double format number X is divided as shown in Figure 2. The value v of X is inferred from its constituent fields thus:

- 1) If $e = 2\ 047$ and $f \neq 0$, then v is a NaN regardless of s .
- 2) If $e = 2\ 047$ and $f = 0$, then $v = (-1)^s \infty$.
- 3) If $0 < e < 2\ 047$, then $v = (-1)^s 2^{e-1\ 023} (1.f)$.
- 4) If $e = 0$ and $f \neq 0$, then $v = (-1)^s 2^{-1\ 022} (0.f)$ (denormalized numbers).
- 5) If $e = 0$ and $f = 0$, then $v = (-1)^s 0$ (zero).




Figure 2 - Double format

3.3 Extended formats

The single extended and double extended formats encode in an implementation-dependent way the sets of values in 3.1 subject to the constraints of Table 1. This standard allows an implementation to encode some values redundantly, provided that redundancy is transparent to the user in the following sense: an implementation shall either encode every nonzero value uniquely or not distinguish redundant encodings of nonzero values. An implementation may also reserve some bit strings for purposes beyond the scope of this standard; when such a reserved bit string occurs as an operand the result is not specified by this standard.

An implementation of this standard is not required to provide (and the user should not assume) that single extended formats have greater range than double extended formats.

3.4 Combinations of formats

All implementations conforming to this standard shall support the single format. Implementations should support the extended format corresponding to the widest basic format supported, and need not support any other extended format.*

* Only if upward compatibility and speed are important issues should a system supporting the double extended format also support the single extended format.

4. Arrondi

L'arrondi considère un nombre comme infiniment précis et, si nécessaire, le modifie pour l'adapter au format de la destination tout en signalant l'exception d'inexactitude (voir 7.5). Sauf pour la conversion binaire-décimale (dont les conditions plus faibles sont spécifiées en 5.6), chaque opération spécifiée dans l'article 5 doit être effectuée comme si elle produisait tout d'abord un résultat intermédiaire correct avec une précision infinie et avec un domaine illimité, puis exécutait une opération d'arrondi sur ce résultat selon un des modes de cet article.

Les modes d'arrondi affectent toutes les opérations arithmétiques, sauf la comparaison et le calcul du reste. Les modes d'arrondi peuvent affecter les signes des sommes de valeur nulle (voir 6.3) et affectent les seuils au-delà desquels un dépassement (voir 7.3) et un dépassement inférieur (voir 7.4) peuvent être signalés.

4.1 Arrondi au plus près

Une réalisation de cette norme doit fournir un arrondi optimal (au plus près) comme mode d'arrondi par défaut. Dans ce mode, elle doit fournir la valeur représentable la plus proche du résultat théorique infiniment précis; si les deux valeurs représentables les plus proches sont à égale distance du résultat théorique, la valeur fournie sera celle dont le bit de poids faible est égal à zéro. Cependant, un résultat infiniment précis avec une valeur au moins de $2^{E_{\max}} (2 - 2^{-P})$ doit être arrondi à ∞ sans changement de signe; dans ce cas, $E_{\max}$ et P sont déterminés par le format de destination (article 3), à moins que ce dernier ne soit annulé par un mode de précision d'arrondi (voir 4.3).

4.2 Arrondis orientés

Une réalisation doit aussi fournir trois modes d'arrondi orientés au choix de l'utilisateur: arrondi vers $+\infty$, arrondi vers $-\infty$ et arrondi vers 0.

Lors de l'arrondi vers $+\infty$, le résultat doit être la valeur du format (éventuellement $+\infty$) la plus proche du résultat théorique de précision infinie et non inférieure à ce résultat théorique. Lors de l'arrondi vers $-\infty$, le résultat doit être la valeur du format (éventuellement $-\infty$) la plus proche du résultat théorique de précision infinie et non supérieure à ce résultat théorique.

Lors de l'arrondi vers 0, le résultat doit être la valeur du format la plus proche du résultat théorique de précision infinie, et non supérieure en valeur absolue à ce résultat théorique.

4.3 Précision d'arrondi

En général, un résultat est arrondi avec la précision correspondant au format de sa destination. Cependant, certains systèmes donnent des résultats en format double précision ou en format étendu. Sur un tel système, l'utilisateur, qui peut être un compilateur de langage évolué, doit pouvoir spécifier qu'un résultat doit être arrondi en simple précision, même lorsqu'il est mémorisé en format double précision ou

4. Rounding

Rounding takes a number regarded as infinitely precise and, if necessary, modifies it to fit in the destination's format while signalling the inexact exception (see 7.5). Except for binary $\leftrightarrow$ decimal conversion (the weaker conditions of which are specified in 5.6), every operation specified in clause 5 shall be performed as if it first produced an intermediate result correct to infinite precision and with unbounded range, and then rounded that result according to one of the modes in this clause.

The rounding modes affect all arithmetic operations except comparison and remainder. The rounding modes may affect the signs of zero sums (see 6.3), and do affect the threshold beyond which overflow (see 7.3) and underflow (see 7.4) may be signalled.

4.1 Round to nearest

An implementation of this standard shall provide round to nearest as the default rounding mode. In this mode, the representable value nearest to the infinitely precise result shall be delivered; if the two nearest representable values are equally near, the one with its least significant bit equal to zero shall be delivered. However, an infinitely precise result with magnitude at least $2^{E_{\max}} (2 - 2^{-P})$ shall round to ∞ with no change in sign; here $E_{\max}$ and P are determined by the destination format (clause 3) unless overridden by a rounding precision mode (see 4.3).

4.2 Directed roundings

An implementation shall also provide three user-selectable directed rounding modes: round toward $+\infty$, round toward $-\infty$, and round toward 0.

When rounding toward $+\infty$, the result shall be the format's value (possibly $+\infty$) closest to and no less than the infinitely precise result. When rounding toward $-\infty$, the result shall be the format's value (possibly $-\infty$) closest to and no greater than the infinitely precise result.

When rounding toward 0, the result shall be the format's value closest to and no greater in magnitude than the infinitely precise result.

4.3 Rounding precision

Normally a result is rounded to the precision of its destination. However, some systems deliver results only to double or extended destinations. On such a system the user, which may be a high-level language compiler, shall be able to specify that a result be rounded instead to single precision, though it may be stored in the double or

étendu avec un exposant ayant un domaine plus étendu*. De la même manière, un système qui fournit des résultats seulement sous le format étendu double précision doit permettre à l'utilisateur de spécifier l'arrondi en simple ou double précision. Il faut remarquer que pour satisfaire aux spécifications de 4.1, le résultat ne peut pas être entaché de plus d'une erreur d'arrondi.

5. Opérations

Toutes les réalisations conformes à cette norme doivent fournir les opérations suivantes: addition, soustraction, multiplication, division, extraction de racine carrée, calcul du reste, arrondi vers entier en format virgule flottante, conversion entre différents formats de virgule flottante, conversion entre formats virgule flottante et entiers, conversion binaire-décimale et comparaisons. Le fait de considérer la copie sans changement de format comme une opération est une option de la réalisation. Excepté pour la conversion binaire-décimale, chacune des opérations doit être effectuée comme si elle produisait tout d'abord un résultat intermédiaire correct avec une précision infinie et un domaine de valeurs illimité, puis contraignait ce résultat intermédiaire à s'adapter au format de destination (articles 4 et 7). L'article 6 étend les spécifications suivantes de manière à couvrir ± 0 , $\pm \infty$ et les non-nombres; l'article 7 énumère les cas d'exception causés par des opérandes et des résultats hors gamme.

5.1 Arithmétique

Une réalisation doit offrir les opérations d'addition, de soustraction, de multiplication, de division et de calcul du reste pour n'importe quel couple d'opérandes de même format, et ce pour chaque format qui est supporté. Il y a lieu qu'elle offre aussi ces opérations pour des opérandes de format différents. Le format de destination (sans tenir compte de la commande de la précision d'arrondi de 4.3) doit être au moins aussi étendu que le format le plus étendu des opérandes. Tous les résultats doivent être arrondis comme spécifié dans l'article 4.

Lorsque $y \neq 0$, le reste $\gamma = x \text{ REM } y$ est défini quel que soit le mode d'arrondi par la relation mathématique $\gamma = x - y \times n$, où n est l'entier le plus proche de la valeur exacte x/y ; lorsque $|n - x/y| = \frac{1}{2}$, alors n est pair. Ainsi, le reste est toujours exact. Si $\gamma = 0$, son signe doit être celui de x . La commande de précision (voir 4.3) ne doit pas s'appliquer à l'opération de calcul du reste.

* La commande de la précision d'arrondi a pour but de permettre à des systèmes pour lesquels les résultats sont toujours en format double précision ou étendu de simuler, en l'absence de dépassement/dépassement inférieur, la précision des systèmes opérant en simple ou double précision. Il ne convient pas qu'une réalisation fournisse des opérations qui combinent des opérandes de format double précision ou étendu pour produire un résultat en simple précision, ni des opérations qui combinent des opérandes de format étendu double précision pour produire un résultat en double précision, avec seulement une opération d'arrondi.

extended format with its wider exponent range.* Similarly, a system that delivers results only to double extended destinations shall permit the user to specify rounding to single or double precision. Note that to meet the specifications in 4.1, the result cannot suffer more than one rounding error.

5. Operations

All conforming implementations of this standard shall provide operations to add, subtract, multiply, divide, extract the square root, find the remainder, round to integer in floating-point format, convert between different floating-point formats, convert between floating-point and integer formats, convert binary $\leftrightarrow$ decimal, and compare. Whether copying without change of format is considered as an operation is an implementation option. Except for binary $\leftrightarrow$ decimal conversion, each of the operations shall be performed as if it first produced an intermediate result correct to infinite precision and with unbounded range, and then coerced this intermediate result to fit in the destination's format (clauses 4 and 7). Clause 6 augments the following specifications to cover ± 0 , $\pm\infty$, and NaNs; clause 7 enumerates exceptions caused by exceptional operands and exceptional results.

5.1 Arithmetic

An implementation shall provide the add, subtract, multiply, divide, and remainder operations for any two operands of the same format, for each supported format; it should also provide the operations for operands of differing formats. The destination format (regardless of the rounding precision control of 4.3) shall be at least as wide as the wider operand's format. All results shall be rounded as specified in clause 4.

When $y \neq 0$, the remainder $x = x \text{ REM } y$ is defined regardless of the rounding mode by the mathematical relation $x = x - y \times n$, where n is the integer nearest the exact value x/y ; whenever $|n - x/y| = \frac{1}{2}$, then n is even. Thus, the remainder is always exact. If $x = 0$, its sign shall be that of x . Precision control (see 4.3) shall not apply to the remainder operation.

* Control of rounding precision is intended to allow systems the destinations of which are always double or extended to mimic, in the absence of over/underflow, the precisions of systems with single and double destinations. An implementation should not provide operations that combine double or extended operands to produce a single result, nor operations that combine double extended operands to produce a double result, with just one rounding.

5.2 *Racine carrée*

L'opération d'extraction de la racine carrée doit être offerte pour tous les formats supportés. Le résultat est défini et possède un signe positif pour tous les opérandes ≥ 0 à l'exception près que $\sqrt{-0}$ doit être égal à -0 . Le format de destination doit être au moins aussi étendu que celui des opérandes. Le résultat doit être arrondi comme spécifié dans l'article 4.

5.3 *Conversions des formats virgule flottante*

Il doit être possible de convertir des nombres en virgule flottante entre tous les formats supportés. Si le résultat de la conversion a une précision moindre, le résultat doit être arrondi comme spécifié dans l'article 4. La conversion vers un format de précision supérieure, doit être exacte. Il n'y a pas d'exception.

5.4 *Conversion entre virgule flottante et entier*

Il doit être possible d'effectuer des conversions entre tous les formats en virgule flottante supportés. La conversion vers des entiers doit s'effectuer par arrondi comme spécifié dans l'article 4. Les conversions entre formats de nombres entiers en virgule flottante et formats de nombres entiers doit être exacte, à moins qu'une exception ne se produise comme il est spécifié en 7.1.

5.5 *Arrondi de nombres en virgule flottante vers une valeur entière*

Il doit être possible d'effectuer une opération d'arrondi sur un nombre en virgule flottante pour obtenir une valeur entière dans le même format virgule flottante. L'arrondi doit être conforme à la spécification de l'article 4, avec la condition que lors d'un arrondi au plus près, si la différence entre l'opérande non arrondi et le résultat arrondi est exactement un demi, le résultat arrondi est pair.

5.6 *Conversion binaire-décimale*

La conversion entre des chaînes décimales dans un format au moins et des nombres binaires en virgule flottante dans tous les formats de base supportés doit être offerte pour tous les nombres couvrant les domaines spécifiés dans le tableau 2. Les entiers M et N des tableaux 2 et 3 sont tels que les chaînes décimales ont pour valeur $\pm M \times 10^{\pm N}$. En entrée, les zéros de queue doivent être ajoutés ou ôtés de M (dans les limites spécifiées dans le tableau 2) de manière à minimiser N . Lorsque la destination est une chaîne décimale, il y a lieu que son digit le moins significatif soit positionné selon les spécifications du format concernant l'arrondi.

Lorsque l'entier M a une valeur située en dehors du domaine spécifié dans les tableaux 2 et 3, c'est-à-dire lorsque $M \geq 10^9$ pour la simple précision et 10^{17} pour la double précision, le réalisateur peut, en option altérer tous les digits significatifs situés après le neuvième en simple précision et après le dix-septième en double précision en leur donnant d'autres valeurs, en général 0.

5.2 *Square root*

The square root operation shall be provided in all supported formats. The result is defined and has a positive sign for all operands ≥ 0 , except that $\sqrt{-0}$ shall be -0 . The destination format shall be at least as wide as the operand's. The result shall be rounded as specified in clause 4.

5.3 *Floating-point format conversions*

It shall be possible to convert floating-point numbers between all supported formats. If the conversion is to a narrower precision, the result shall be rounded as specified in clause 4. Conversion to a wider precision shall be exact. There is no exception.

5.4 *Conversions between floating-point and integer*

It shall be possible to convert between all supported floating-point formats and all supported integer formats. Conversion to integer shall be effected by rounding as specified in clause 4. Conversions between floating-point integers and integer formats shall be exact unless an exception arises as specified in 7.1.

5.5 *Round floating-point number to integral value*

It shall be possible to round a floating-point number to an integral valued floating-point number in the same format. The rounding shall be as specified in clause 4, with the understanding that when rounding to nearest, if the difference between the unrounded operand and the rounded result is exactly one half, the rounded result is even.

5.6 *Binary $\leftrightarrow$ decimal conversion*

Conversion between decimal strings in at least one format, and binary floating-point numbers in all supported basic formats, shall be provided for numbers throughout the ranges specified in Table 2. The integers M and N in Tables 2 and 3 are such that the decimal strings have values $\pm M \times 10^{\pm N}$. On input, trailing zeros shall be appended to or stripped from M (up to the limits specified in Table 2) in order to minimize N . When the destination is a decimal string, its least significant digit should be located by format specifications for purposes of rounding.

When the integer M lies outside the range specified in Tables 2 and 3, i.e. when $M \geq 10^9$ for single or 10^{17} for double, the implementor may, at his option, alter all significant digits after the ninth for single and seventeenth for double, to other decimal digits, typically 0.

Les conversions doivent être arrondies correctement, comme spécifié dans l'article 4 pour les opérandes inclus dans les domaines spécifiés dans le tableau 3. Sinon, dans le cas d'arrondi au plus près, l'erreur du résultat converti ne doit pas excéder de plus de 0,47 unités du digit le moins significatif du résultat l'erreur qui résulterait de l'application des spécifications d'arrondi de l'article 4, pour autant qu'il n'y ait aucun dépassement de capacité concernant l'exposant. Pour les modes d'arrondi orientés, l'erreur doit avoir le signe correct et ne doit pas dépasser 1,47 unités de plus faible poids.

Les conversions doivent être monotones. C'est-à-dire que l'augmentation de la valeur d'un nombre binaire exprimé en virgule flottante ne doit pas se traduire par une diminution de sa valeur après conversion en une chaîne décimale; et une augmentation de la valeur d'une chaîne décimale ne doit pas se traduire par une diminution de sa valeur après conversion en un nombre binaire en virgule flottante.

Lorsqu'une opération d'arrondi au plus près est effectuée, la conversion de binaire à décimal et réciproquement doit être l'identité tant que la chaîne décimale possède la précision maximale spécifiée dans le tableau 2, c'est-à-dire 9 digits en simple précision et 17 digits en double précision*.

Si la conversion décimale-binaire donne lieu à un dépassement supérieur ou inférieur, la réponse sera comme spécifié dans l'article 7. Il convient que les conditions de dépassement supérieur et inférieur, les non-nombres et les valeurs infinies apparaissant lors des conversions binaire à décimal soient signalées à l'utilisateur par des chaînes appropriées. Cette norme ne donne aucune information à propos du traitement des non-nombres codés sous forme de chaînes décimales.

Pour éviter des incohérences, il convient que les procédures utilisées pour la conversion binaire-décimale fournissent les mêmes résultats, que la conversion soit effectuée lors de la traduction du langage (interprétation, compilation ou assemblage) ou lors de l'exécution du programme (exécution et entrée/sortie interactive).

Tableau 2 - Domaine de conversion décimale

Format	Décimal-binaire		Binaire-décimal	
	$M_{\max.}$	$N_{\max.}$	$M_{\max.}$	$N_{\max.}$
Simple précision	$10^9 - 1$	99	$10^9 - 1$	53
Double précision	$10^{17} - 1$	999	$10^{17} - 1$	340

* Les propriétés spécifiées pour les conversions résultent des limites d'erreur qui dépendent du format (simple ou double précision) et du nombre de chiffres décimaux qui interviennent; la valeur 0,47 mentionnée correspond à la limite pour le pire des cas. Pour une discussion détaillée de ces bornes d'erreur et des algorithmes de conversion économiques qui utilisent le format étendu, se référer à "Accurate Yet Economical Binary ↔ Decimal conversions" par Jerome T. Coonen (Ph.D. Dissertation, Université de Californie, Berkeley).

Conversions shall be correctly rounded as specified in clause 4 for operands lying within the ranges specified in Table 3. Otherwise, for rounding to nearest, the error in the converted result shall not exceed by more than 0.47 units in the destination's least significant digit the error that would be incurred by the rounding specifications of clause 4, provided that exponent over/underflow does not occur. In the directed rounding modes the error shall have the correct sign and shall not exceed 1.47 units in the last place.

Conversions shall be monotonic. That is, increasing the value of a binary floating-point number shall not decrease its value when converted to a decimal string; and increasing the value of a decimal string shall not decrease its value when converted to a binary floating-point number.

When rounding to the nearest, conversion from binary to decimal and back to binary shall be the identity as long as the decimal string is carried to the maximum precision specified in Table 2, namely, 9 digits for single and 17 for double.*

If decimal to binary conversion over/underflows, the response is as specified in clause 7. Over/underflow and NaNs and infinities encountered during binary to decimal conversion should be indicated to the user by appropriate strings. This standard says nothing about dealing with NaNs encoded in decimal strings.

To avoid inconsistencies, the procedures used for binary ↔ decimal conversion should give the same results regardless of whether the conversion is performed during language translation (interpretation, compilation or assembly) or during program execution (run-time and interactive input/output).

Table 2 - Decimal conversion ranges

Format	Decimal to binary		Binary to decimal	
	Max. <i>M</i>	Max. <i>N</i>	Max. <i>M</i>	Max. <i>N</i>
Single	$10^9 - 1$	99	$10^9 - 1$	53
Double	$10^{17} - 1$	999	$10^{17} - 1$	340

* The properties specified for conversions are implied by error bounds that depend on the format (single or double) and the number of decimal digits involved; the 0.47 mentioned is a worst-case bound only. For a detailed discussion of these error bounds and economical conversion algorithms that exploit the extended format, see "Accurate Yet Economical Binary ↔ Decimal Conversions" by Jerome T. Coonen (Ph.D. Dissertation, University of California, Berkeley).

Tableau 3 - Domaine d'arrondi exact pour la conversion décimale

Format	Décimal-binaire		Binaire-décimal	
	$M_{\max.}$	$N_{\max.}$	$M_{\max.}$	$N_{\max.}$
Simple précision	$10^9 - 1$	13	$10^9 - 1$	13
Double précision	$10^{17} - 1$	27	$10^{17} - 1$	27

5.7 Comparaison

Il doit être possible de comparer des nombres en virgule flottante dans tous les formats supportés, même si les formats des opérandes sont différents. Les comparaisons sont exactes et ne créent jamais de dépassement de capacité. Il existe quatre relations possibles, qui s'excluent mutuellement: "plus petit que", "égal", "plus grand que" et "non ordonné". Ce dernier cas survient lorsqu'un des opérandes au moins est un non-nombre. Chaque non-nombre doit donner "non ordonné" comme résultat de la comparaison avec tout élément y compris lui-même. Les comparaisons doivent ignorer le signe de zéro (ainsi $+0 = -0$).

Le résultat d'une comparaison doit être fourni selon l'une des deux manières suivantes: soit comme un code condition identifiant l'une des quatre relations indiquées ci-dessus, ou comme une réponse binaire (vrai-faux) à un prédicat qui identifie la comparaison spécifique désirée. En supplément à la réponse vrai-faux, une condition d'exception d'opération invalide (voir 7.1) doit être signalée quand, comme indiqué dans la dernière colonne du tableau 4, des opérandes "non ordonnés" sont comparés en utilisant un des prédicats mettant en oeuvre "<" ou ">" mais pas "?". Le symbole "?" signifie ici "non ordonné".

Le tableau 4 montre les vingt-six prédicats fonctionnellement distincts identifiés, dans la première colonne, au moyen de trois notations: ad hoc, FORTRAN et mathématique. Il montre comment ils sont obtenus à partir des quatre codes conditions et indique quels prédicats sont la cause d'une exception d'opération invalide lorsque la relation est "non ordonné". Les entrées V et F indiquent si le prédicat est vrai ou faux lorsque la relation correspondante est vérifiée.

Table 3 - Correctly rounded decimal conversion range

Format	Decimal to binary		Binary to decimal	
	Max. <i>M</i>	Max. <i>N</i>	Max. <i>M</i>	Max. <i>N</i>
Single	$10^9 - 1$	13	$10^9 - 1$	13
Double	$10^{17} - 1$	27	$10^{17} - 1$	27

5.7 Comparison

It shall be possible to compare floating-point numbers in all supported formats, even if the operands' formats differ. Comparisons are exact and never overflow nor underflow. Four mutually exclusive relations are possible: "less than," "equal," "greater than," and "unordered". The last case arises when at least one operand is NaN. Every NaN shall compare "unordered" with everything, including itself. Comparisons shall ignore the sign of zero (so $+0 = -0$).

The result of a comparison shall be delivered in one of the two following ways: either as a condition code identifying one of the four relations listed above, or as a true-false response to a predicate that names the specific comparison desired. In addition to the true-false response, an invalid operation exception (see 7.1) shall be signalled when, as indicated in the last column of Table 4, "unordered" operands are compared, using one of the predicates involving "<" or ">" but not "?". (Here the symbol "?" signifies "unordered".)

Table 4 exhibits the twenty-six functionally distinct useful predicates named, using three notations in the first column: ad hoc, FORTRAN-like, and mathematical. It shows how they are obtained from the four condition codes and tells which predicates cause an invalid operation exception when the relation is "unordered". The entries T and F indicate whether the predicate is true or false when the respective relation holds.

Tableau 4 - Prédicats et relations

Prédicats			Relations				Exceptions
Ad hoc	FORTTRAN	Math	Plus grand que	Plus petit que	Egal	Non ordonné	Invalidé si non ordonné
=	.EQ.	=			V	F	Non
?<>	.NE.	≠	V	V	F	V	Non
>	.GT.	>	V	F	F	F	Oui
>=	.GE.	>=	V	F	V	F	Oui
<	.LT.	<		V	F	F	Oui
<=	.LE.	<=		V	V	F	Oui
?	non ordonné				F	V	Non
<>	.LG.		V	V	F	F	Oui
<=>	.LEG.		V	V	V	F	Oui
?>	.UG.		V	F	F	V	Non
?>=	.UGE.		V	F	V	V	Non
?<	.UL.			V	F	V	Non
?<=	.ULE.			V	V	V	Non
?=	.UE.			F	V	V	Non
NON(>)				V	V	V	Oui
NON(>=)				V	F	V	Oui
NON(<)			V	F	V	V	Oui
NON(<=)			V	F	F	V	Oui
NON(?)			V	V	V	F	Non
NON(<>)				F	V	V	Oui
NON(<=>)				F	F	V	Oui
NON(?>)				V	V	F	Non
NON(?>=)				V	F	F	Non
NON(?<)			V	F	V	F	Non
NON(?<=)			V	F	F	F	Non
NON(?=)			V	V	F	F	Non

Remarquer que les prédicats s'associent par paires, chacun étant la négation logique de l'autre; l'application d'un préfixe comme "NON" pour effectuer la négation d'un prédicat dans le tableau 4 échange le sens des valeurs vrai et faux des entrées associées, mais laisse la dernière colonne inchangée*.

Les réalisations qui offrent des prédicats doivent fournir les 6 premiers prédicats du tableau 4 et il convient qu'elles fournissent aussi le septième, ainsi que le moyen d'effectuer la négation logique des prédicats.

* Il peut sembler qu'il existe deux façons d'écrire la négation logique d'un prédicat, l'une utilisant "NON" de manière explicite et l'autre inversant l'opérateur relationnel. Par exemple, la négation logique de $(X=Y)$ peut s'écrire soit $NON(X=Y)$ ou $(X \neq Y)$; dans ce cas, les deux expressions sont fonctionnellement équivalentes à $(X \neq Y)$. Cependant, cette coïncidence ne se produit pas pour les autres prédicats. Par exemple, la négation logique de $(X < Y)$ est seulement $NON(X < Y)$; le prédicat inverse $(X \geq Y)$ est différent en ce sens qu'il ne signale pas d'exception d'opération invalide lorsque X et Y sont "non ordonnés".

Table 4 - Predicates and relations

Predicates			Relations				Exception
Ad hoc	FORTAN	Math	Greater than	Less than	Equal	Unordered	Invalid if unordered
=	.EQ.	=	F	F	T	F	No
?<>	.NE.	≠	T	T	F	T	No
>	.GT.	>	T	F	F	F	Yes
>=	.GE.	>=	T	F	T	F	Yes
<	.LT.	<	F	T	F	F	Yes
<=	.LE.	<=	F	T	T	F	Yes
?	unordered		F	F	F	T	No
<>	.LG.		T	T	F	F	Yes
<=>	.LEG.		T	T	T	F	Yes
?>	.UG.		T	F	F	T	No
?>=	.UGE.		T	F	T	T	No
?<	.UL.		F	T	F	T	No
?<=	.ULE.		F	T	T	T	No
?=	.UE.		F	F	T	T	No
NOT(>)			F	T	T	T	Yes
NOT(>=)			F	T	F	T	Yes
NOT(<)			T	F	T	T	Yes
NOT(<=)			T	F	F	T	Yes
NOT(?)			T	T	T	F	No
NOT(<>)			F	F	T	T	Yes
NOT(<=>)			F	F	F	T	Yes
NOT(?>)			F	T	T	F	No
NOT(?>=)			F	T	F	F	No
NOT(?<)			T	F	T	F	No
NOT(?<=)			T	F	F	F	No
NOT(?=)			T	T	F	F	No

Note that predicates come in pairs, each a logical negation of the other; applying a prefix like "NOT" to negate a predicate in Table 4 reverses the true/false sense of its associated entries, but leaves the last column's entry unchanged.*

Implementations that provide predicates shall provide the first six predicates in Table 4 and should provide the seventh, as well as a means of logically negating predicates.

* There may appear to be two ways to write the logical negation of a predicate, one using "NOT" explicitly and the other reversing the relational operator. For example, the logical negation of $(X=Y)$ may be written either $\text{NOT}(X=Y)$ or $(X \neq Y)$; in this case, both expressions are functionally equivalent to $(X \neq Y)$. However, this coincidence does not occur for the other predicates. For instance, the logical negation of $(X < Y)$ is just $\text{NOT}(X < Y)$; the reversed predicate $(X \geq Y)$ is different in that it does not signal an invalid operation exception when X and Y are "unordered".

6. Infini, non-nombres et zéro signé

6.1 Arithmétique de l'infini

L'arithmétique de l'infini doit être considérée comme le cas limite de l'arithmétique réelle, avec des opérandes de valeur aussi grande que l'on veut, lorsqu'une telle limite existe. Les infinis doivent s'interpréter au sens affine, c'est-à-dire que $-\infty < (\text{tout nombre fini}) < +\infty$.

L'arithmétique sur ∞ est toujours exacte et, pour cette raison, ne doit signaler aucune exception, sauf pour les opérations invalides spécifiées pour ∞ en 7.1. Les cas d'exception qui relèvent de ∞ sont signalés seulement dans les cas suivants:

- 1) ∞ est créé à partir d'opérandes finis par dépassement de capacité (voir 7.3), ou par une division par zéro (voir 7.2), avec le déroutement correspondant désactivé, ou
- 2) ∞ est un opérande invalide (voir 7.1).

6.2 Opérations avec des non-nombres

Deux types de non-nombres, indicateur et muet, doivent être supportés dans toutes les opérations. Les non-nombres indicateurs autorisent des valeurs pour les variables non initialisées et des améliorations de type arithmétique (telles que les infinités complexes-affines ou les domaines d'amplitude extrême) qui sont en dehors de l'objet de cette norme. Il y a lieu que les non-nombres muets, par des moyens laissés à la discrétion du réalisateur, fournissent des informations de diagnostic rétrospectif héritées des données et résultats invalides ou non disponibles. La propagation des informations de diagnostic nécessite que l'information contenue dans les non-nombres soit préservée à travers les opérations arithmétiques et les conversions de format en virgule flottante.

Les non-nombres indicateurs doivent être des opérandes réservés qui signalent les conditions d'exception d'opération invalide (voir 7.1) pour chaque opération indiquée dans l'article 5. La décision de signaler une exception d'opération invalide lors de la copie d'un non-nombre indicateur sans changement de format est laissée au réalisateur comme option.

Toute opération portant sur un non-nombre indicateur ou toute opération invalide (voir 7.1) doit, si aucun déroutement ne se produit et si un résultat en virgule flottante est attendu, fournir un non-nombre muet comme résultat.

Toute opération portant en entrée sur un ou deux non-nombres, aucun n'étant un non-nombre indicateur, ne doit pas signaler d'exception, mais, si un résultat en virgule flottante est attendu, doit fournir comme résultat un non-nombre muet, qui appartiendrait à un des non-nombres d'entrée. Remarque qu'il est possible que les conversions de format ne puissent fournir le même non-nombre. Les non-nombres muets ont des effets semblables aux non-nombres indicateurs qui ne fournissent pas de résultat en virgule flottante; ces opérations, à savoir la comparaison et la conversion à un format dépourvu de non-nombres, sont détaillés en 5.4, 5.6, 5.7 et 7.1.

6. Infinity, NaNs, and signed zero

6.1 *Infinity arithmetic*

Infinity arithmetic shall be construed as the limiting case of real arithmetic with operands of arbitrarily large magnitude, when such a limit exists. Infinities shall be interpreted in the affine sense, that is, $-\infty < (\text{every finite number}) < +\infty$.

Arithmetic on ∞ is always exact and therefore shall signal no exceptions, except for the invalid operations specified for ∞ in 7.1. The exceptions that do pertain to ∞ are signalled only when

- 1) ∞ is created from finite operands by overflow (see 7.3) or division by zero (see 7.2), with the corresponding trap disabled, or
- 2) ∞ is an invalid operand (see 7.1).

6.2 *Operations with NaNs*

Two different kinds of NaN, signalling and quiet, shall be supported in all operations. Signalling NaNs afford values for uninitialized variables and arithmetic-like enhancements (such as complex-affine infinities or extremely wide range) that are not the subject of the standard. Quiet NaNs should, by means left to the implementor's discretion, afford retrospective diagnostic information inherited from invalid or unavailable data and results. Propagation of the diagnostic information requires that information contained in the NaNs be preserved through arithmetic operations and floating-point format conversions.

Signalling NaNs shall be reserved operands that signal the invalid operation exception (see 7.1) for every operation listed in clause 5. Whether copying a signalling NaN without a change of format signals the invalid operation exception is the implementor's option.

Every operation involving a signalling NaN or invalid operation (see 7.1) shall, if no trap occurs and if a floating-point result is to be delivered, deliver a quiet NaN as its result.

Every operation involving one or two input NaNs, none of them signalling, shall signal no exception but, if a floating-point result is to be delivered, shall deliver as its result a quiet NaN, which should be one of the input NaNs. Note that format conversions might be unable to deliver the same NaN. Quiet NaNs have effects similar to signalling NaNs on operations that do not deliver a floating-point result; these operations, namely comparison and conversion to a format that has no NaNs, are discussed in 5.4, 5.6, 5.7 and 7.1.

6.3 Bit de signe

Cette norme ne parle pas du signe d'un non-nombre. Dans les autres cas, le signe d'un produit ou d'un quotient s'obtient par le "OU exclusif" des signes des opérandes; et le signe de la somme, ou de la différence $x - y$ considérée comme la somme $x + (-y)$, diffère de l'un des signes des termes au plus. Ces règles doivent s'appliquer même lorsque les opérandes ou les résultats sont zéro ou l'infini.

Lorsque la somme de deux opérandes de signes contraires (ou la différence de deux opérandes de même signe) est exactement nulle, le signe de cette somme (ou différence) doit être "+" dans tous les modes d'arrondi, sauf l'arrondi vers $-\infty$, auquel cas ce signe doit être "-". Cependant, $x + x = x - (-x)$ conserve le même signe que x même lorsque x est nul.

A l'exception près que $\sqrt{-0}$ doit avoir la valeur -0 , toute racine carrée valide doit avoir un signe positif.

7. Exceptions

Il y a cinq cas d'exceptions qui doivent être signalés lorsqu'ils sont détectés. Cette signalisation peut consister à positionner un indicateur d'état, exécuter un déroutement, ou éventuellement effectuer les deux. A chaque exception, il convient qu'un déroutement soit associé sous contrôle de l'utilisateur, comme spécifié dans l'article 8. La réponse par défaut à une exception doit être de poursuivre sans déroutement. Cette norme spécifie les résultats devant être fournis selon les deux cas, déroutement et non-déroutement. Dans certains cas, le résultat est différent lorsqu'un déroutement est activé.

Pour chaque type d'exception, la réalisation doit fournir un indicateur d'état qui doit être mis à un lors de toute occurrence de l'exception correspondante lorsqu'aucun déroutement ne se produit. Cet indicateur doit être remis à zéro seulement à la demande de l'utilisateur. Ce dernier doit pouvoir tester et modifier les indicateurs d'état individuellement et, de plus, il y a lieu qu'il puisse sauvegarder et restaurer les cinq indicateurs en bloc.

Les seules exceptions qui peuvent coïncider sont "inexact avec dépassement" et "inexact avec dépassement inférieur".

7.1 Opérations invalides

L'exception d'opération invalide est signalée lorsqu'un des opérandes est invalide pour l'opération à exécuter. Le résultat, lorsque l'exception se produit sans déroutement, doit être un non-nombre muet (voir 6.2), pourvu que la destination ait un format virgule flottante. Les opérations invalides sont les suivantes:

- 1) Toute opération sur un non-nombre indicateur (voir 6.2).
- 2) Addition ou soustraction: soustraction en valeur absolue de valeurs infinies comme $(+\infty) + (-\infty)$.
- 3) Multiplication $0 \times \infty$.

6.3 The sign bit

This standard does not interpret the sign of a NaN. Otherwise the sign of a product or quotient is the "Exclusive OR" of the operands' signs; and the sign of a sum, or of a difference $x - y$ regarded as a sum $x + (-y)$, differs from at most one of the addends' signs. These rules shall apply even when operands or results are zero or infinite.

When the sum of two operands with opposite signs (or the difference of two operands with like signs) is exactly zero, the sign of that sum (or difference) shall be "+" in all rounding modes except round towards $-\infty$, in which mode that sign shall be "-". However, $x + x = x - (-x)$ retains the same sign as x even when x is zero.

Except that $\sqrt{-0}$ shall be -0 , every valid square root shall have a positive sign.

7. Exceptions

There are five types of exceptions that shall be signalled when detected. The signal entails setting a status flag, taking a trap, or possibly doing both. With each exception should be associated a trap under user control, as specified in clause 8. The default response to an exception shall be to proceed without a trap. This standard specifies results to be delivered in both trapping and non-trapping situations. In some cases the result is different if a trap is enabled.

For each type of exception the implementation shall provide a status flag that shall be set on any occurrence of the corresponding exception when no corresponding trap occurs. It shall be reset only at the user's request. The user shall be able to test and to alter the status flags individually, and should further be able to save and restore all five at one time.

The only exceptions that can coincide are inexact with overflow and inexact with underflow.

7.1 Invalid operations

The invalid operation exception is signalled if an operand is invalid for the operation to be performed. The result, when the exception occurs without a trap, shall be a quiet NaN (see 6.2) provided the destination has a floating-point format. The invalid operations are:

- 1) Any operation on a signalling NaN (see 6.2).
- 2) Addition or subtraction: magnitude subtraction of infinities like $(+\infty) + (-\infty)$.
- 3) Multiplication $0 \times \infty$.

- 4) Division $0/0$ ou ∞/∞ .
- 5) Calcul du reste: $x \text{ REM } y$, où y est nul ou x est infini.
- 6) Racine carrée: si l'opérande est négatif.
- 7) Conversion d'un nombre binaire en virgule flottante en un format entier ou décimal lorsqu'un dépassement de capacité, la présence de valeurs infinies ou de non-nombres empêchent une représentation fidèle dans ce format, et que ce fait ne peut pas être signalé autrement, et
- 8) comparaison utilisant des prédicats impliquant "<" ou ">", sans "?", lorsque les opérandes sont "non ordonnés" (voir 5.7, tableau 4).

7.2 Division par zéro

Si le diviseur est nul et le dividende un nombre fini non nul, alors l'exception division par zéro doit être signalée. Le résultat, lorsqu'aucun déroutement n'a lieu, doit être la valeur ∞ avec le signe correct (voir 6.3).

7.3 Dépassement de capacité

L'exception de dépassement de capacité doit être signalée lorsque la valeur du plus grand nombre fini représentable dans le format de destination est dépassée par le résultat théorique en virgule flottante avec arrondi qui serait obtenu si le domaine de l'exposant était illimité (article 4). Le résultat lorsqu'aucun déroutement ne se produit, doit être déterminé par le mode d'arrondi et le signe du résultat intermédiaire comme suit:

- 1) Dans le mode d'arrondi au plus près, tous les dépassements donnent le résultat ∞ avec le signe du résultat intermédiaire.
- 2) Dans le mode d'arrondi vers 0, tous les dépassements donnent comme résultat le plus grand nombre fini du format avec le signe du résultat intermédiaire.
- 3) Dans le mode d'arrondi vers $-\infty$, tous les dépassements positifs donnent comme résultat le plus grand nombre fini du format et les dépassements négatifs donnent $-\infty$ comme résultat.
- 4) Dans le mode d'arrondi vers $+\infty$, tous les dépassements négatifs donnent comme résultat le nombre fini négatif le plus petit du format et les dépassements positifs donnent $+\infty$ comme résultat.

Les dépassements donnant lieu à un déroutement doivent fournir à la routine de traitement de déroutement associée et pour toutes les opérations sauf les conversions, le résultat obtenu en divisant le résultat infiniment précis par 2^α puis en effectuant l'arrondi. L'ajustement d'excédent α est de 192 pour le format simple précision, de 1 536 en double précision, et de $3 \times 2^{n-2}$ dans le format étendu où n repré-

- 4) Division $0/0$ or ∞/∞ .
- 5) Remainder $x \text{ REM } y$, where y is zero or x is infinite.
- 6) Square root if the operand is less than zero.
- 7) Conversion of a binary floating-point number to an integer or decimal format when overflow, infinity, or NaN precludes a faithful representation in that format and this cannot otherwise be signalled; and
- 8) Comparison via predicates involving "<" or ">", without "?", when the operands are "unordered" (see 5.7, Table 4).

7.2 Division by zero

If the divisor is zero and the dividend is a finite non-zero number, then the division by zero exception shall be signalled. The result, when no trap occurs, shall be a correctly signed ∞ (see 6.3).

7.3 Overflow

The overflow exception shall be signalled whenever the destination format's largest finite number is exceeded in magnitude by what would have been the rounded floating-point result (clause 4) were the exponent range unbounded. The result, when no trap occurs, shall be determined by the rounding mode and the sign of the intermediate result as follows:

- 1) Round to nearest carries all overflows to ∞ with the sign of the intermediate result.
- 2) Round toward 0 carries all overflows to the format's largest finite number, with the sign of the intermediate result.
- 3) Round toward $-\infty$ carries positive overflows to the format's largest finite number, and carries negative overflows to $-\infty$.
- 4) Round toward $+\infty$ carries negative overflows to the format's most negative finite number, and carries positive overflows to $+\infty$.

Trapped overflows on all operations except conversions shall deliver to the trap handler the result obtained by dividing the infinitely precise result by 2^α and the rounding. The bias adjust α is 192 in the single, 1 536 in the double, and $3 \times 2^{n-2}$ in the extended format,

sente le nombre de bits du champ de l'exposant*. Les dépassements avec déroutements sur conversion de format binaire en virgule flottante doivent fournir à la routine de traitement de déroutement un résultat dans ce même format ou un format supérieur, avec éventuellement un ajustement de l'excédent de l'exposant, mais avec un arrondi correspondant à la précision de la destination. Les dépassements avec déroutements sur conversion décimale-binaire doivent fournir à la routine de traitement de déroutement un résultat dans le format le plus grand supporté, éventuellement avec un ajustement de l'excédent de l'exposant, mais avec un arrondi correspondant à la précision de la destination; lorsque le résultat a une valeur telle que l'exposant ne peut être ajusté, le dépassement doit fournir un non-nombre muet.

7.4 Dépassement de capacité inférieur

Deux événements corrélés contribuent à un dépassement inférieur. L'un est la création d'un résultat infinitésimal non nul de valeur comprise entre $\pm 2^{E_{\min}}$ qui, à cause de sa petitesse, peut être la cause de quelque autre exception ultérieure, telle qu'un dépassement de capacité par division. L'autre est la perte considérable de précision lors de l'approximation par des nombres dénormalisés de tels nombres infinitésimaux. Le réalisateur peut choisir la manière dont ces événements sont détectés, mais doit détecter ces événements de la même manière pour toutes les opérations. La petitesse peut être détectée soit:

- 1) "après arrondi" lorsqu'un résultat non nul, calculé comme si le domaine de l'exposant était illimité, est compris strictement entre $\pm 2^{E_{\min}}$,
- ou
- 2) "avant arrondi" lorsqu'un résultat non nul, calculé comme si le domaine de l'exposant ainsi que la précision étaient tous deux illimités, serait compris strictement entre $\pm 2^{E_{\min}}$,

Une perte de précision peut se détecter soit comme:

- 3) une perte de dénormalisation: lorsque le résultat fourni diffère de la valeur qui aurait été obtenue si le domaine de l'exposant avait été illimité,
- ou
- 4) un résultat inexact: lorsque le résultat fourni diffère de la valeur qui aurait été obtenue si le domaine de l'exposant ainsi que la précision avaient été illimités. (C'est la condition appelée inexac-titude en 7.5.)

* L'ajustement d'excédent est choisi de manière à décaler les valeurs correspondant aux dépassements supérieur et inférieur aussi près que possible du milieu du domaine de l'exposant, afin que, si on le désire, ces valeurs puissent être utilisées lors d'opérations ultérieures avec moins de risque de production de nouvelles exceptions.

where n is the number of bits in the exponent field.* Trapped overflow on conversion from a binary floating-point format shall deliver to the trap handler a result in that, or a wider format - possibly with the exponent bias adjusted - but rounded to the destination's precision. Trapped overflow on decimal to binary conversion shall deliver to the trap handler a result in the widest supported format, possibly with the exponent bias adjusted, but rounded to the destination's precision; when the result lies too far outside the range for the bias to be adjusted, a quiet NaN shall be delivered instead.

7.4 Underflow

Two correlated events contribute to underflow. One is the creation of a tiny nonzero result between $\pm 2^{E_{\min}}$ which, because it is so tiny, may cause some other exception later such as overflow upon division. The other is extraordinary loss of accuracy during the approximation of such tiny numbers by denormalized numbers. The implementor may choose how these events are detected, but shall detect these events in the same way for all operations. Tininess may be detected either:

- 1) "after rounding": when a nonzero result computed as though the exponent range were unbounded would lie strictly between $\pm 2^{E_{\min}}$,
or
- 2) "before rounding": when a nonzero result computed as though both the exponent range and the precision were unbounded would lie strictly between $\pm 2^{E_{\min}}$.

Loss of accuracy may be detected as either:

- 3) a denormalization loss: when the delivered result differs from what would have been computed were exponent range unbounded;
or
- 4) an inexact result: when the delivered result differs from what would have been computed were both exponent range and precision unbounded. (This is the condition called inexact in 7.5.)

* The bias adjust is chosen to translate over/underflowed values as nearly as possible to the middle of the exponent range so that, if desired, they can be used in subsequent scaled operations with less risk of causing further exceptions.

Lorsqu'un déroutement associé à un dépassement de capacité n'est pas réalisé ou n'est pas activé (le cas par défaut), le dépassement de capacité doit être signalé (par l'intermédiaire de l'indicateur de dépassement inférieur) seulement lorsque la petitesse du résultat et la perte de précision ont été toutes deux détectées. La méthode de détection de la petitesse et de la perte de précision n'affecte pas le résultat fourni qui peut être zéro, dénormalisé ou $\pm 2^{E_{\min}}$. Lorsqu'un déroutement pour dépassement de capacité inférieur a été réalisé et se trouve activé, le dépassement de capacité inférieur doit être signalé lorsque la petitesse est détectée quelle que soit la perte de précision. Pour toutes les opérations, sauf la conversion, les dépassements de capacité inférieurs avec déroutement doivent fournir à la routine de traitement de déroutement le résultat obtenu en multipliant le résultat théorique infiniment précis par 2^α puis en effectuant un arrondi. L'ajustement d'excédent α est de 192 en simple précision, de 1 536 en double précision, et de $3 \times 2^{n-2}$ en format étendu, où n est le nombre de bits dans le champ de l'exposant*. Les dépassements de capacité inférieurs avec déroutement sur conversion doivent être traités de manière similaire au traitement des dépassements de capacité supérieurs sur conversion.

7.5 Inexactitude

Si le résultat arrondi d'une opération n'est pas exact ou s'il donne lieu à un dépassement de capacité, alors l'exception d'inexactitude doit être signalée. Le résultat arrondi ou avec dépassement de capacité doit être fourni à la destination ou, si un déroutement sur inexactitude se produit, à la routine de traitement de cette exception.

8. Déroutements

Il convient qu'un utilisateur puisse disposer d'un déroutement pour chacun des cinq cas d'exception en spécifiant une routine de traitement de déroutement pour celui-ci. Il y a lieu qu'il puisse commander qu'une routine de traitement existante soit désactivée, sauvegardée ou restaurée. Il convient aussi qu'il puisse déterminer si une routine de traitement de déroutement spécifique a été activée. Lorsqu'une exception dont le déroutement a été désactivé est signalée, elle doit être traitée de la manière spécifiée dans l'article 7. Lorsqu'une exception dont le déroutement est activé est signalée, l'exécution du programme dans lequel l'exception s'est produite doit être suspendue, la routine de traitement de déroutement préalablement spécifiée par l'utilisateur doit être exécutée, et un résultat, si spécifié dans l'article 7, doit lui être fourni.

* Remarquer qu'un système dont le matériel sous-jacent déclenche toujours des déroutements sur dépassement de capacité inférieur, produisant un résultat arrondi, à l'exposant ajusté, doit indiquer si un tel résultat est arrondi en valeur absolue, de manière que le résultat correctement dénormalisé puisse être produit par le logiciel du système lorsque le déroutement de dépassement de capacité inférieur de l'utilisateur est désactivé.

When an underflow trap is not implemented or is not enabled (the default case) underflow shall be signalled (via the underflow flag) only when both tininess and loss of accuracy have been detected. The method for detecting tininess and loss of accuracy does not affect the delivered result which might be zero, denormalized or $\pm 2^{E_{\min}}$. When an underflow trap has been implemented and is enabled, underflow shall be signalled when tininess is detected regardless of loss of accuracy. Trapped underflows on all operations except conversion shall deliver to the trap handler the result obtained by multiplying the infinitely precise result by 2^α and then rounding. The bias adjust α is 192 in the single, 1 536 in the double, and $3 \times 2^{n-2}$ in the extended format, where n is the number of bits in the exponent field.* Trapped underflows on conversion shall be handled analogously to the handling of overflows on conversion.

7.5 Inexact

If the rounded result of an operation is not exact or if it overflows without an overflow trap, then the inexact exception shall be signalled. The rounded or overflowed result shall be delivered to the destination, or, if an inexact trap occurs, to the trap handler.

8. Traps

A user should be able to request a trap on any of the five exceptions by specifying a handler for it. He should be able to request that an existing handler be disabled, saved or restored. He should also be able to determine whether a specific trap handler for a designated exception has been enabled. When an exception whose trap is disabled is signalled, it shall be handled in the manner specified in clause 7. When an exception whose trap is enabled is signalled, the execution of the program in which the exception occurred shall be suspended, the trap handler previously specified by the user shall be activated, and a result, if specified in clause 7, shall be delivered to it.

* Note that a system the underlying hardware of which always traps on underflow, producing a rounded, bias-adjusted result, must indicate whether such a result is rounded up in magnitude in order that the correctly denormalized result may be produced in system software when the user underflow trap is disabled.