



**Regeling van het College voor examens van 15 april 2014,
nummer CvE-14.01040, houdende vaststelling van regels voor de omzetting
van scores in cijfers bij centrale examinering in het mbo (Regeling omzetting
scores in cijfers bij centrale examinering mbo)**

Het College voor examens,

Gelet op artikel 3 van de Wet College voor examens; en het Examen- en kwalificatiebesluit beroepsopleidingen WEB artikel 6, eerste lid onderdeel g;

Gezien de goedkeuring van de Minister van Onderwijs, Cultuur en Wetenschap, gegeven op 12 mei 2014, nummer 629707;

Besluit:

Artikel 1 omzetting score in cijfers

De omzetting van scores in cijfers, bedoeld in artikel 6, eerste lid onderdeel g van het Examen- en kwalificatiebesluit beroepsopleidingen WEB geschiedt op de in de bijlage bij deze regeling vastgestelde wijze.

Artikel 2 bekendmaking

De regeling zal met de bijlage en toelichting in de Staatscourant worden geplaatst. De bijlage kan ook geraadpleegd worden op Examenbladmbo.nl.

Artikel 3 inwerkingtreding

Deze regeling treedt in werking met ingang van 1 augustus 2014.

Artikel 4 citeertitel

Deze regeling wordt aangehaald als: Regeling omzetting scores in cijfers bij centrale examinering mbo.

*Het College voor examens,
Namens deze,
de voorzitter,
H.W. Laan*

BIJLAGE BEHORENDE BIJ ARTIKEL 1 VAN DE REGELING OMZETTING SCORES IN CIJFERS BIJ CENTRALE EXAMINERING MBO, VAN 15 APRIL 2014, NUMMER CVE-14.01040

Normering met een vaardigheidsschaal bij de centrale examens Nederlandse taal en rekenen in het mbo en de Rekentoets VO (RVO)

Doel van normering met een vaardigheidsschaal


Zoals gebruikelijk bij toetsen en examens, worden bij de rekentoetsen VO en de centrale examens Nederlandse taal en rekenen in het MBO cijfers toegekend. De manier waarop deze cijfers bepaald worden, noemen we 'normering met een vaardigheidsschaal'.

Het gebruik van een vaardigheidsschaal is vooral geschikt als er meerdere varianten van een examen zijn. De ene variant kan net iets makkelijkere opgaven hebben dan de andere variant. Dit kan gebeuren omdat de moeilijkheid van een opgave niet heel precies ingeschat kan worden voordat deze is voorgelegd aan examenkandidaten. Bij het toekennen van cijfers moet daar rekening mee gehouden worden. Op de makkelijkere varianten moet een kandidaat dan iets meer vragen goed beantwoord hebben om een 6 te krijgen. We kunnen ook zeggen: een kandidaat moet eenzelfde vaardigheid aantonen voor een 6, ongeacht de variant die hij maakt, ongeacht het jaar waarin het examen wordt afgelegd dan wel de examenperiode binnen dat jaar. En dit moet ook gelden voor ieder ander cijfer. Ongeacht de variant die gemaakt wordt, moet eenzelfde aangetoonde vaardigheid steeds beloond worden met eenzelfde cijfer.

Metten van vaardigheid

Het cijfer dat toegekend wordt, wordt dus bepaald door de vaardigheid die een kandidaat heeft. Deze vaardigheid kan hij aantonen door opgaven van een examen goed te maken. Het examen is daarmee een meetinstrument geworden van de vaardigheid van de kandidaat. En net zoals een thermometer een meetinstrument is van de temperatuur, op de Celsius- of Fahrenheit-schaal, zo spreken we ook van een vaardigheidsschaal.

De lengte van mensen meten we normaal gesproken met een meetlat. Stel dat die niet uitgevonden was, dan zouden we de hoogte van muurtjes kunnen gebruiken om de lengte van mensen te meten: wie erover heen kijkt, is langer dan degene die dat niet kan. Op analoge wijze kunnen we opgaven gebruiken om de vaardigheid van kandidaten te meten: wie de opgave goed maakt, is vaardiger dan degene die dat niet kan. In Figuur 1 is een vaardigheidsschaal afgebeeld. De vaardigheden van de kandidaten en de moeilijkheden van de opgaven zijn streepjes op eenzelfde meetlat ofwel schaal. Kandidaten met een hoge vaardigheid hebben een grotere kans om opgaven goed te maken dan kandidaten met een lagere vaardigheid. Omgekeerd, opgaven met een hoge moeilijkheid worden minder vaak goed gemaakt dan opgaven met een lage moeilijkheid.



Figuur 1. Afbeelding van personen en opgaven op één vaardigheidsschaal

Een opgave heeft altijd dezelfde moeilijkheid; een examenvariant kan bestaan uit makkelijkere of moeilijker opgaven. Een mini-examenvariant met alleen opgave 6 en opgave 3 uit bovenstaand voorbeeld, is bijvoorbeeld gemakkelijker dan een mini-examenvariant met alleen opgave 3 en opgave 28. Uit het antwoordgedrag van voldoende leerlingen op de makkelijke variant, kunnen we afleiden hoeveel makkelijker opgave 6 is dan opgave 3. Uit het antwoordgedrag van andere leerlingen op de moeilijke variant, kunnen we afleiden hoeveel moeilijker opgave 28 is dan opgave 3. Door een koppeling van deze twee verschillen, kunnen we afleiden hoeveel moeilijker opgave 28 is dan opgave 6. Op deze manier kunnen de moeilijkheden van alle opgaven op dezelfde schaal worden afgebeeld. Meer details over de schatting van itemmoeilijkheden staan in de sectie Schattingsmethode.

Getallen bij de vaardigheidsschaal

De schattingen van punten op de vaardigheidsschaal liggen vast op een lineaire transformatie na. We mogen bij alle punten dus een willekeurig aantal optellen, of alle punten met een willekeurige constante vermenigvuldigen. Een vaardigheidsschaal wordt geschat om scores op verschillende examenvarianten met elkaar te vergelijken. De precieze getallen die eraan hangen, zijn in wezen keuzes. Het nulpunt komt vrij willekeurig ergens te liggen. Negatieve vaardigheidsscores zijn lager dan vaardigheidsscore 0. Dit heeft geen inhoudelijke betekenis. We hadden bij alle scores ook 100 punten op kunnen tellen. In technische termen: de vaardigheidsschaal is van interval-niveau. Vergelijk met een temperatuur-schaal: het nulpunt op de Fahrenheit-schaal ligt ergens anders dan op de Celsius-schaal, maar voor beide geldt: hoe hoger, hoe warmer.

Je kunt bij temperatuur niet spreken van 'het is vandaag twee keer zo warm als gisteren', want voor zo'n uitspraak is een absoluut nulpunt nodig. Dat is er op de Fahrenheit- en Celsius-schaal niet. Zo kun je dus ook niet zeggen dat een kandidaat twee keer zo vaardig is als een andere kandidaat. Er is wel een inhoudelijke betekenis van negatieve graden op de Celsius-schaal (het vriest), maar op de Fahrenheit-schaal vriest het al onder 32 graden en is deze inhoudelijke betekenis van negatieve temperaturen er dus niet. Zo'n inhoudelijke betekenis van het nulpunt is er bij de vaardigheidsschaal ook niet.

Om nog technischer te worden: de ratio van twee verschillen is bij een interval-schaal wel interpreteerbaar. Dus als Jan, Mo, Mieke en Melissa respectievelijk 80, 90, 100 en 120 als vaardigheidsscores hebben, dan kun je wel zeggen dat het verschil in vaardigheid tussen de meisjes Mieke en Melissa (20 punten) twee keer zo groot is als het verschil tussen de jongens Jan en Mo (10 punten).

Van score naar vaardigheid

Als de moeilijkheden van alle opgaven of items in een examenperiode geschat zijn, wordt een beste schatting van de vaardigheid van een kandidaat gemaakt¹ aan de hand van de items die de kandidaat daadwerkelijk zijn voorgelegd. Van alle antwoorden die een kandidaat geeft, wordt eerst de ruwe score berekend, ofwel het aantal behaalde punten. In combinatie met de itemkenmerken waarop deze ruwe score behaald is, wordt de vaardigheid geschat. Dit gebeurt per examenvariant voor iedere ruwe score apart, zie bijvoorbeeld tabel 1 voor een gedeelte van de omzettingstabel van score naar vaardigheid bij variant 2 van een toets of examen. De relatie tussen score en vaardigheid hoeft niet rechtlijnig te zijn. Dit hangt af van de onderlinge verschillen in moeilijkheid tussen de opgaven.

Tabel 1. Voorbeeld van een omzettingstabel score naar vaardigheid

Variant	Score	Vaardigheid
...	...	...
V2	30	66.5
V2	31	70.0
V2	32	73.7
V2	33	77.8
V2	34	82.3
V2	35	87.3
V2	36	93.0
...	...	...

Deze methode levert dus per examenvariant een tabel op met achter iedere mogelijke ruwe score een vaardigheidsschatting. De ruwe score loopt van 0 tot en met de maximale score. De vaardigheidsschatting heeft niet overal dezelfde nauwkeurigheid. Bij de allerlaagste en allerhoogste scores is de meetnauwkeurigheid lager dan ergens in het midden van de scores. De exacte score waarbij de meetnauwkeurigheid het hoogst is, hangt af van de moeilijkheid van de opgaven in de examenvariant.

Als er opgaven in een examenvariant zitten, waarover de normeringsvergadering beslist dat zij niet mee mogen tellen bij de beoordeling van een kandidaat, dan noemen we dit geneutraliseerde items. Alle kandidaten krijgen voor een geneutraliseerd item het maximale aantal punten dat behaald kan worden. Bij de schatting van de itemparameters doen de geneutraliseerde items niet mee, alleen de antwoorden op de overige items worden gebruikt voor het vaststellen van de vaardigheidsschaal. Bij de schatting worden de geneutraliseerde items buiten beschouwing gelaten.

¹ De gebruikte schatting is een weighted maximum likelihood (WML) schatter bij de ongewogen score. Verhelst en Engelen (1999) tonen aan dat dit een veralgemenisering is van de WML-schatter bij gewogen scores (Warm, 1989).

De vaardigheid van de kandidaat wordt dus eigenlijk geschat aan de hand van de antwoorden op een verkorte examenvariant, waarin de geneutraliseerde items niet opgenomen zijn. In tabel 2 staat een voorbeeld van de omzettingstabel van score naar vaardigheid als er in een variant, waarop maximaal 54 punten behaald kunnen worden, drie geneutraliseerde items van ieder maximaal 1 punt zijn. De schatting van de vaardigheid gaat uitsluitend over de verkorte variant, met scores 0 tot en met 51. De rapportage gaat over de gehele range 0 tot en met 54. De 'neutrale punten' worden bij de verkorte score opgeteld om tot de score op de volledige variant te komen. In de rapportage-tabel staat achter de scores 0, 1 en 2 dezelfde vaardigheid als bij de laagst mogelijke score 3, namelijk vaardigheid 75. Echter, in praktijk komen deze scores niet voor omdat iedere kandidaat minimaal 3 punten scoort, namelijk op de geneutraliseerde items.


Tabel 2. Vaardigheidsscores bij een examenvariant met 3 geneutraliseerde items van ieder 1 punt

Schatting		Rapportage	
Score verkorte variant	Vaardigheid	Score volledige variant	Vaardigheid
Nvt	nvt	0	75
Nvt	nvt	1	75
Nvt	nvt	2	75
0	75	3	75
1	83	4	83
2	86	5	86
...		...	
51	212	54	212

Noot. Gerapporteerde scores 0,1 en 2 komen niet voor, vanwege de geneutraliseerde items.

Van vaardigheid naar cijfer

Door middel van IRT-schaling worden alle kandidaten en opgaven op dezelfde vaardigheidsschaal afgebeeld. Cijfers reflecteren de waardering voor behaalde vaardigheid. Het belangrijkste punt op de vaardigheidsschaal is de cesuur: vanaf de cesuur-vaardigheid wordt de vaardigheid van kandidaten als voldoende beoordeeld. Een vaardigheid onder de cesuur wordt als onvoldoende beoordeeld. Om afrondingsproblemen te voorkomen, is het precieze cijfer dat wordt toegekend bij de cesuur-vaardigheid afhankelijk van het aantal gerapporteerde decimalen. Als hele cijfers gerapporteerd worden, zoals bij de Rekentoets VO of het centraal examen Rekenen, is het cijfer bij de cesuur een 5,5. Als cijfers met één decimaal worden gerapporteerd, zoals bij het centraal examen Taal, is het cijfer bij de cesuur gelijk aan 5,45. In Figuur 2 is dit bij vaardigheid 83,0.



Figuur 2. Voorbeeld van omzetting van vaardigheidsscores naar cijfers

De omzetting van vaardigheid naar cijfer is lineair met een knik. Dat wil zeggen dat er een rechtlijnig verband is tussen cijfer en vaardigheid boven de cesuur, en dat er een ander rechtlijnig verband is onder de cesuur. Om de relaties exact vast te leggen, worden door de normeringsvergadering nog twee cijferpunten op de vaardigheidsschaal vastgelegd: één boven de cesuur en één onder de cesuur. Boven de cesuur is dit punt het cijfer 7,5, waarmee het cijfer 8 of hoger wordt toegekend aan kandidaten met een goede vaardigheid. Onder de cesuur wordt het cijfer 4,5 of 3,5 vastgesteld. De drie punten op de vaardigheidsschaal die de omzetting van vaardigheid naar cijfer bepalen, noemen we ook wel standaarden. De rechte lijnen die door de drie punten bepaald worden, worden naar boven en beneden afgekapt. Cijfer boven 10,0 en onder 1,0 worden immers niet toegekend. Het bepalen van de waarden van standaarden wordt Standaardsetting genoemd. Meestal worden daarvoor de oordelen van experts gebruikt. Er zijn diverse methodes waarbij deze experts oordelen per opgave moeten geven, of waarbij zij oordelen over sets van opgaven moeten geven.

Schattingsmethode


Om de moeilijkheid van de opgaven precies te schatten, wordt gebruik gemaakt van item respons theorie (IRT). Opgaven worden binnen deze theorie items genoemd. De antwoorden van leerlingen worden responsen genoemd. De kans dat een bepaalde kandidaat een bepaald item goed beantwoordt, is afhankelijk van de vaardigheid van de persoon en van kenmerken van het item, zoals de moeilijkheid ervan. De vaardigheid van een kandidaat wordt met de Griekse letter θ aangeduid. De kans dat een kandidaat met een vaardigheid θ een item goed maakt, wordt omschreven met een wiskundige formule of functie. Van de familie van modellen die binnen de IRT vallen, wordt in dit geval het one parameter logistic model (OPLM, Glas & Verhelst, 1989, Verhelst & Glas, 1993; Verhelst, Glas & Verstralen, 1993; Verhelst & Eggen, 2011) gebruikt. De itemresponsfunctie van het OPLM is gegeven door

waarin a_i de zogenaamde discriminatie-index van het item is, en β_i de moeilijkheidsparameter van

$$f_i(\theta) = \frac{\exp[a_i(\theta - \beta_i)]}{1 + \exp[a_i(\theta - \beta_i)]},$$

item i is. In Figuur 3 zijn de itemresponscurven weergegeven van twee items i en j , die even moeilijk zijn maar verschillend discrimineren. Als de vaardigheid van de kandidaat gelijk is aan de moeilijkheid van een opgave, dan heeft hij een kans van 50% om de opgave goed te maken. Opgaven met een hoge discriminatie-index onderscheiden beter tussen hoog- en laagvaardige kandidaten, ofwel de

kans om een opgave goed te maken neemt hierbij snel toe met θ . De index a_i wordt ook wel de hellingsparameter genoemd.




Figuur 3. Twee itemresponscurven in het OPLM: zelfde moeilijkheid, verschillende discriminatie-index

Een vaak toegepaste schattingsmethode voor de moeilijkheidsparameters β_i is de 'conditionele grootste aannemelijkheidsmethode' (in het Engels: Conditional Maximum Likelihood, verder aangeduid als CML). Die maakt gebruik van het feit dat in het model een afdoende steekproefgrootte ('sufficient statistic') bestaat voor de latente variabele θ , namelijk de ruwe score of het aantal correct beantwoorde items. Dat betekent grofweg dat, indien de itemparameters bekend zijn, alle informatie die het antwoordpatroon over de vaardigheid bevat, kan worden samengevat in de ruwe score; het doet er dan verder niet meer toe welke opgaven goed en welke fout zijn gemaakt. Hieruit vloeit voort dat de conditionele kans op een juist antwoord op item i , gegeven de ruwe score, een functie is die alleen afhankelijk is van de itemparameters en onafhankelijk van de waarde van θ ². De CML-schattingsmethode maakt van deze functie gebruik. Deze methode maakt geen enkele vooronderstelling over de verdeling van de vaardigheid in de populatie, en is ook onafhankelijk van de wijze waarop de steekproef is getrokken. Door de indices a_i te beperken tot (positieve) gehele getallen, en door ze a priori als constanten in te voeren, is het mogelijk CML-schattingen van de itemparameters β_i te maken.

Standaardsetting

Bij een standaardsetting wordt een punt op de vaardigheidsschaal bepaald (figuur 5). Uitgangspunt voor de standaardbepaling was de gehanteerde procedure en de bijbehorende uitkomsten van het standaardsettingsonderzoek bij de referentiesets. Bij de referentiesets is gebruik gemaakt van standaardsetting-procedures met beoordelaars, in casu de **Angoff-procedure** en de **Bookmark-procedure**. Merk op dat deze methoden niet beperkt hoeven te zijn tot de cesuur voor een voldoende, maar ook toegepast kunnen worden voor het cijfer 5 of 8.

². Een gedetailleerde uiteenzetting hierover kan men vinden in Verhelst, 1992.



Figuur 4. Standaard (125) op een vaardigheidsschaal

Angoff-procedure

Bij een Angoff-procedure moeten de experts een grenskandidaat in gedachten nemen. Een grenskandidaat is een kandidaat die het vereiste niveau net beheerst. De experts geven per item aan of een grenskandidaat deze goed maakt of niet. Bij een gemodificeerde Angoff-procedure wordt per item door de experts de kans ingeschat dat een grenskandidaat de opgave goed maakt. Dit is hetzelfde als inschatten hoeveel van 100 grenskandidaten de opgave goed maken. Optellen van de kansen van alle opgaven van een bepaald examen of toets geeft de grensscore die gehaald moet worden op het betreffende examen of toets om te voldoen aan minimale eisen: de cesuur. Deze cesuur wordt vervolgens afgebeeld op de vaardigheidsschaal, waarmee de standaard bepaald is.

Bookmark-procedure

Als er ook afnamegegevens beschikbaar zijn, kan ook gewerkt worden met een Bookmark-procedure, waarbij gebruik gemaakt wordt van de empirische ordening van de items naar moeilijkheid (Van der Schoot, 2001, 2008). Deze procedure voor het vaststellen van een standaard voor een bepaald niveau maakt gebruik van een reeks opgaven die naar moeilijkheid zijn gerangschikt. Deskundigen geven aan welke opgave nog wel en welke niet meer beheerst zouden moeten worden door een grenskandidaat. In de reeks opgaven plaatsen zij een 'bookmark'. Experts geven dus aan hoeveel items van een set opgaven beheerst moeten worden op een bepaald niveau. Dit oordeel wordt weer omgezet in een punt op de vaardigheidsschaal.

Hieronder wordt voor rekenen en Nederlandse taal beschreven hoe de standaardsettingsprocedure is verlopen.

Procedure rekenen

Gedurende de standaardbepalingsprocedure van de referentiesets rekenen is gebruik gemaakt van de Extended Angoff methode. Voor deze procedure zijn de panelleden in drie groepen verdeeld. Bij de groepsindeling is rekening gehouden met de achtergrond van panelleden. Elke groep heeft een gedeelte van het materiaal beoordeeld. Na een individuele beoordelingsronde (ronde 1) hebben de panelleden in kleine groepen de opgaven besproken. Tijdens deze discussieronde was het mogelijk om het oordeel dat in de individuele ronde gegeven was aan te passen (ronde 2). De discussieronde is zodanig georganiseerd dat de opgaven in kleine groepen van wisselende samenstelling zijn besproken. Aangezien slechts een gedeelte van de opgaven door een panellid beoordeeld is, is door middel van een omzettingstabel (gebaseerd op een vaardigheidsschaal) de grensscore op het beoordeelde gedeelte geëxtrapoleerd naar de volledige referentieset.

Naast de Extended Angoff procedure is ook een Bookmarkprocedure uitgevoerd. Voor deze procedure

is op basis van de verzamelde data de moeilijkheid van opgaven bepaald³. De opgaven zijn vervolgens geordend van makkelijk naar moeilijk. Panelleden konden aangeven tot en met welke opgave een grenskandidaat een kans van 67% of minder had om de opgave goed te maken.

De uitkomsten van beide procedures zijn in een plenaire discussie voorgelegd aan de panelleden. Hierbij werd weergegeven wat het percentage leerlingen zou zijn dat het referentieniveau zou halen. Daarnaast is deze voorlopige cesuur vergeleken met reeds vastgestelde cesuren, namelijk de tot nu toe gehanteerde rekenen 2F en 3F standaarden voor de centrale examens en de Rekentoets VO. Vervolgens hebben alle experts op schrift een definitief oordeel gegeven. Het gemiddelde van deze oordelen geldt vervolgens als uiteindelijk advies aan het College voor examens.

Procedure Nederlandse taal

Gedurende de standaardbepalingsprocedure is gebruik gemaakt van de Extended Angoff methode. Voor deze procedure zijn de panelleden in vier groepen verdeeld. Elke groep heeft een gedeelte van het materiaal beoordeeld. Na een individuele beoordelingsronde (ronde 1) hebben de panelleden in kleine groepen de opgaven besproken. Tijdens deze discussieronde was het mogelijk om het oordeel dat in de individuele ronde gegeven was aan te passen (ronde 2).

Na afloop van deze discussieronde konden experts hun oordelen intekenen in een figuur. In deze figuur werden de opgaven die een expert beoordeeld had afgebeeld op de volledige schaal van de referentieset. Door zorgvuldig de oordelen uit de inhoudelijke rondes in de figuur in te tekenen kon het oordeel op een gedeelte van de opgaven daarmee geëxtrapoleerd worden naar de volledige referentieset. Zo konden experts tot een eerste advies over de cesuur op de volledige referentieset komen.

Naar aanleiding van dit eerste advies is nagegaan wat de gemiddelde cesuur van alle panelleden op de referentieset zou zijn. Voor deze cesuur is bekeken wat het percentage kandidaten zou zijn dat het referentieniveau zou halen. Daarnaast is deze voorlopige cesuur vergeleken met reeds vastgestelde cesuren, namelijk de CENTRALE EXAMENS Taal 2F en 3F-cesuur. Vervolgens hebben alle experts op schrift een definitief oordeel gegeven. Het gemiddelde van deze oordelen geldt vervolgens als uiteindelijk advies aan het College voor Examens. Het College heeft de adviezen overgenomen en vastgesteld.

Omzetting referentiecesuur naar cesuur centraal examen taal en rekenen en RVO-cesuur

Door de items uit de referentieset rekenen en die uit de varianten van de centrale examens rekenen en de RVO af te beelden op dezelfde vaardigheidsschaal (zie figuur 1 en de beschrijving in paragraaf 4) wordt de referentiecesuur (= de cesuur van de referentieset) overgebracht op iedere variant van het centraal examen rekenen en de RVO. Geheel analoog wordt de referentiecesuur Nederlandse taal op de varianten van de centrale examens Nederlandse taal overgebracht.

Omzetting van scores in cijfers

Van iedere toets- en examenvariant wordt de omzetting van scores in cijfers bepaald door de scores om te zetten vaardigheidsniveaus op de wijze waarop dat in paragraaf 4 is beschreven en door de vaardigheidsniveaus om te zetten in cijfers volgens paragraaf 5. De omzetting van scores verloopt daardoor via een vaardigheidsschaal.

Tabel 3a is een voorbeeld van een omzettingstabel van scores – via vaardigheidsniveaus – in cijfers.

Mogelijkheid van maatwerk bij de normering

Het is mogelijk om bij de normering met een andere cesuur dan de referentiecesuur te werken. In 2013 is dit voor het eerst gebeurd bij de normering van de rekentoets 2F. Toen is de cesuur voor de kandidaten in de gemengde en theoretische leerweg één cijferpunt hoger gelegd dan de referentiecesuur, terwijl de cesuur voor de kandidaten in de basisberoepsgerichte leerweg één cijferpunt lager lag. Tabel 3b respectievelijk 3c is een voorbeeld van een omzettingstabel waarbij de cesuur één cijferpunt lager respectievelijk hoger ligt dan bij de omzetting van scores in cijfers volgens tabel 3a.

³ Moeilijkheid is hier uitgedrukt in p-waarde. Hierbij is een gewogen p-waarde gehanteerd waarbij alle beschikbare data van alle schooltypen meegenomen is.

tabel 3a omzettingstabel (voorbeeld waarbij de cesuur ligt bij een fictief vaardigheidsniveau van 105,7)

score	vaardig-	cijfer
0	-16,0	1
1	23,1	1
2	38,8	1
3	48,3	1
4	55,0	1
5	60,1	1
6	64,2	1
7	67,7	2
8	70,7	2
9	73,4	2
10	75,8	3
11	78,0	3
12	80,0	3
13	81,9	3
14	83,6	3
15	85,3	4
16	86,8	4
17	88,3	4
18	89,7	4
19	91,1	4
20	92,4	4
21	93,6	4
22	94,8	4
23	96,0	5
24	97,1	5
25	98,3	5
26	99,4	5
27	100,4	5
28	101,5	5
29	102,5	5
30	103,6	5
31	104,6	5
32	105,6	5
33	106,6	6
34	107,6	6
35	108,7	6
36	109,7	6
37	110,7	6
38	111,7	6
39	112,8	6
40	113,9	7
41	115,0	7
42	116,1	7
43	117,2	7
44	118,4	7
45	119,6	7
46	120,9	7
47	122,3	8
48	123,7	8
49	125,2	8
50	126,8	8
51	128,5	8
52	130,5	9
53	132,6	9
54	135,0	9
55	137,9	9
56	141,4	10
57	145,8	10
58	151,9	10
59	161,4	10
60	182,9	10

tabel 3a

tabel 3b omzettingstabel (voorbeeld waarbij de cesuur één cijferpunt lager ligt dan in tabel 3a))

score	vaardig-	cijfer
0	-16,0	1
1	23,1	1
2	38,8	1
3	48,3	1
4	55,0	2
5	60,1	2
6	64,2	2
7	67,7	3
8	70,7	3
9	73,4	3
10	75,8	4
11	78,0	4
12	80,0	4
13	81,9	4
14	83,6	4
15	85,3	5
16	86,8	5
17	88,3	5
18	89,7	5
19	91,1	5
20	92,4	5
21	93,6	5
22	94,8	5
23	96,0	6
24	97,1	6
25	98,3	6
26	99,4	6
27	100,4	6
28	101,5	6
29	102,5	6
30	103,6	6
31	104,6	6
32	105,6	6
33	106,6	7
34	107,6	7
35	108,7	7
36	109,7	7
37	110,7	7
38	111,7	7
39	112,8	7
40	113,9	8
41	115,0	8
42	116,1	8
43	117,2	8
44	118,4	8
45	119,6	8
46	120,9	8
47	122,3	9
48	123,7	9
49	125,2	9
50	126,8	9
51	128,5	9
52	130,5	10
53	132,6	10
54	135,0	10
55	137,9	10
56	141,4	10
57	145,8	10
58	151,9	10
59	161,4	10
60	182,9	10

tabel 3b

tabel 3c omzettingstabel (voorbeeld waarbij de cesuur één cijferpunt hoger ligt dan in tabel 3a))

score	vaardig-	cijfer
0	-16,0	1
1	23,1	1
2	38,8	1
3	48,3	1
4	55,0	1
5	60,1	1
6	64,2	1
7	67,7	1
8	70,7	1
9	73,4	1
10	75,8	2
11	78,0	2
12	80,0	2
13	81,9	2
14	83,6	2
15	85,3	3
16	86,8	3
17	88,3	3
18	89,7	3
19	91,1	3
20	92,4	3
21	93,6	3
22	94,8	3
23	96,0	4
24	97,1	4
25	98,3	4
26	99,4	4
27	100,4	4
28	101,5	4
29	102,5	4
30	103,6	4
31	104,6	4
32	105,6	4
33	106,6	5
34	107,6	5
35	108,7	5
36	109,7	5
37	110,7	5
38	111,7	5
39	112,8	5
40	113,9	6
41	115,0	6
42	116,1	6
43	117,2	6
44	118,4	6
45	119,6	6
46	120,9	6
47	122,3	7
48	123,7	7
49	125,2	7
50	126,8	7
51	128,5	7
52	130,5	8
53	132,6	8
54	135,0	8
55	137,9	8
56	141,4	9
57	145,8	9
58	151,9	10
59	161,4	10
60	182,9	10

tabel 3c

Literatuur

Engen, T. J. H. M., & Verhelst, N. D. (2011). Item calibration in incomplete testing designs. *Psicologica: International Journal of Methodology and Experimental Psychology*, 32, 107–132.

Glas, C. A. W., & Verhelst, N.D. (1989). Extensions of the partial credit model, *Psychometrika*, 54, 635–659.

Van der Schoot, F. (2001). *Standaarden voor kerndoelen basisonderwijs. De ontwikkeling van standaarden voor kerndoelen basisonderwijs op basis van resultaten uit peilingsonderzoek*. (Proefschrift Universiteit van Amsterdam). Arnhem, Cito.

Van der Schoot, F. (2008). *Onderwijs op peil? Een samenvattend overzicht van 20 jaar PPON*. Arnhem, Cito.

Verhelst, N.D., & Engelen, R.J.H. (1999). *An ability estimator in the two parameter logistic model based on raw scores*. Research memorandum. Arnhem: Cito.



Verhelst, N.D., & Glas, C.A.W. (1993). A dynamic generalization of the Rasch model. *Psychometrika*, 58, 395-415.

Verhelst, N.D., Glas, C.A.W., & Verstralen, H.H.F.M. (1993). OPLM: One parameter logistic model. Computer program and manual. Arnhem: Cito.

Warm, T.A. (1989). Weighted likelihood estimation of ability in item response theory. *Psychometrika*, 54, 427-450.



TOELICHTING BEHORENDE BIJ DE REGELING OMZETTING SCORES IN CIJFERS BIJ CENTRALE EXAMENS MBO, VAN 15 APRIL 2014, NUMMER CVE-14.01040

Met deze regeling, die op 12 mei 2014 is goedgekeurd door de Minister van Onderwijs, Cultuur en Wetenschap, geeft het College voor examens invulling aan de hem in artikel 6, eerste lid onderdeel g van het Examen- en kwalificatiebesluit beroepsopleidingen WEB opgedragen taak om regels te stellen voor de omzetting van centrale examen scores in cijfers.

Gelet op de aard van betreffende voorschriften zijn deze niet opgenomen in de regeling zelf, maar in de daarbij behorende bijlage.

In de bijlage wordt de systematiek beschreven om te kunnen normeren met behulp van een vaardigheidsschaal. Daarvoor is op de eerste plaats nodig dat elke opgave van een examen wordt gekalibreerd op de desbetreffende vaardigheidsschaal. Elke examenvariant bestaat uit een aantal examenopgaven die tezamen de schaalverdeling vormen van het examen op de vaardigheidsschaal. Vervolgens wordt de vaardigheid van de kandidaat geschat door middel van het aantal correcte antwoorden op de desbetreffende examenvariant. Het totaal aantal correcte antwoorden correspondeert met een bijbehorende vaardigheidsscore. Door middel van een IRT-schalingstechniek wordt van alle kandidaten en opgaven op dezelfde vaardigheidsschaal afgebeeld. Het tweede onderdeel wordt gevormd door de standaardsettingsmethode. In de bijlage worden de twee methodes beschreven die zijn toegepast van Nederlandse taal en rekenen, namelijk de Angoff-methode en de bookmark-procedure. In beide gevallen hebben inhoudelijke experts bepaald op welk punt van de vaardigheidsschaal de minimale norm voor beheersing op elk Centraal Examen (2F/ 3F, Nederlandse taal en rekenen) gelegd moet worden. Op basis van deze norm wordt van iedere examenvariant bepaald hoe de omzetting van een vaardigheidsscore naar een bijbehorend cijfer moet verlopen. Door te werken met de normering op een vaardigheidsschaal kan worden gegarandeerd dat rekening gehouden wordt met verschillen in moeilijkheidsgraad tussen examenopgaven en examenvarianten. Dat betekent dat de norm voor (on)voldoende voor alle kandidaten hetzelfde is. Ten slotte is aangegeven dat via maatwerk een andere normering gehanteerd kan worden die afwijkt van de hiervoor beschreven procedure.

*Het College voor examens,
Namens deze,
de voorzitter,
H.W. Laan*