今さら聞けないがんを対象とした 単群phase II試験

国立がん研究センター研究支援センター
生物統計部

水澤 純基

2021. 2.22

生物統計セミナー発展編

典型的なphase2のデザイン

- 対象：がん種を限定
- 登録数：20-60例
- デザイン：単群でオープンラベル
- Endpoint：RECISTによる奏効割合
  - できるだけ早くphase IIIに進むかどうかを決める
    - 開発を続けるに値するかどうかの判断に用いる
    - 治療の利益というより、生物学的な抗腫瘍活性の存在を確認
  - 有効性によるスクリーニング

閾値と期待値

第II相試験の意思決定に必要な知識：閾値と期待値

● 閾値と期待値

- **閾値**：これ以下の値であれば開発をあきらめる値
  - 最低限クリアして欲しい値
  - いわゆる「帰無仮説（≡意味のある効果なし）」に対応
- **期待値**：これ以上の値であれば是非開発を続けたいと考える値

● どう決める？

- 検定で意思決定する場合に直接関係するのは**閾値**
- 「比べたい相手」 = 「標準治療」は何かを考える
- 標準治療と比較したリスクバランスを考える

単群のphase 2試験は怎么样了たらpositiveか？

- 有意水準 α に対応する割合の信頼区間が**閾値**を上回ればpositive

検定でpositive/negativeの判断には期待値は関係ないので、閾値の設定が肝

ケース：どの設定が妥当？

条件設定：

- Primary endpointは奏効割合のPhase 2
- 標準治療の奏効割合は20%。
- 今回の試験治療は標準治療に上乘せすることになるため、毒性が強くなる

問い：あなたであれば、どの閾値を選択しますか？

1. 閾値=15%
2. 閾値=20%
3. 閾値=25%

Phase 2 単群試験の期待値の設定

- 基本的な考え方は「そのくらいの値が得られるのであれば是非、開発を続けたい」と考える値
- 考慮すべきは以下の2点
  - 標準治療と比較した毒性とのバランス（臨床的意味）
  - 本当にそれだけの有効性が期待できるか
- 実際は、phase 2のサンプルサイズの目安はおおよそ決まっており、それに基づいて期待値を動かすことも多い
  - Nは少なすぎず、多すぎず、ほどほどに

閾値・期待値とNの関係

- 大きな治療効果を期待するのであれば少ないNでOK

例： $\alpha=5\%$ 、検出力=80%、閾値=10%の場合

解析対象数と信頼区間の幅の関係

解析対象数が増えれば、信頼区間の幅は狭くなる

割合の点推定値が10%の場合

- 10人中1人 → 95% CI[0.3%-44.5%]
- 20人中2人 → 95% CI[1.2%-31.7%]
- 50人中5人 → 95% CI[3.3%-21.8%]
- 100人中10人 → 95% CI[4.9%-17.6%]
- 200人中20人 → 95% CI[6.2%-15.0%]
- 1000人中100人 → 95% CI[8.3%-12.0%]

信頼係数と信頼区間の幅の関係

信頼係数が小さくなれば、信頼区間の幅は狭くなる

割合の点推定値が10%の場合

- 50人中5人 → 99% CI[2.2%-25.8%]
- 50人中5人 → 95% CI[3.3%-21.8%]
- 50人中5人 → 90% CI[4.0%-19.9%]
- 50人中5人 → 80% CI[4.9%-17.8%]
- 50人中5人 → 50% CI[6.8%-14.5%]

検定と区間推定の関係

- 検定と区間推定は1:1の対応関係がある

片側有意水準（両側）	片側p値	両側p値	両側信頼区間(CI)
0.025 (0.05)	$P < 0.025$	$= P < 0.05$	95% CIが帰無仮説を含まない
0.05 (0.1)	$P < 0.05$	$= P < 0.1$	90% CIが帰無仮説を含まない
0.1 (0.2)	$P < 0.1$	$= P < 0.2$	80% CIが帰無仮説を含まない

P値をみなくても、設定した有意水準と信頼区間から
検定結果が有意かどうか分かる

理解のための問題：有意？ or 有意じゃない？

1. 閾値20%(=帰無仮説)、両側有意水準=5%の設定

- 奏効割合 = 34% 95% CI[21.2%-48.8%]

2. 閾値20%、両側有意水準=5%の設定

- 奏効割合 = 30% 95% CI[17.9%-44.6%]

3. 閾値20%、片側有意水準=5%の設定

- 奏効割合 = 32% 90% CI[21.2%-44.5%]

4. 閾値20%、片側有意水準 = 5%の設定

- 奏効割合 = 34% 95% CI[21.2%-48.8%]

5. 閾値20%、片側有意水準=5%の設定

- 奏効割合 = 32% 95% CI[19.5%-46.7%]

1-stage vs 2-stage デザイン

単一標本デザイン(1段階法 or 1 stage法)

- 途中で解析・登録停止することなく、
目標被験者数まで一気に登録
  - 最後に検定して有意 (p 値 $<a$) ならpositive
- サンプルサイズ計算に必要な情報
  - 閾値(p_0)
  - 期待値(p_1)
  - α
  - β

がんのphase II段階で真に有効なものは20%程度

Fig. 2 | Probability of launch from phases I, II and III by therapeutic area from 2010–2017.

無効なものが多いのであれば、患者に対する倫理的配慮が必要

2-stageデザイン

- 登録の途中で1度、有効性を評価する方法
  - 途中で中間評価を行う
  - 登録を止めて規準を満たすことが判明した後に登録再開が原則
- 例：JCOG0807（切除不能・再発食道がんに対するDCF療法）
  - 閾値35%(CF療法の奏効割合)、期待値50%、 $\alpha=10\%$ 、検出力=80%
  - SWOGの2-stage design(後述)で50例。1st stageで25例

2-stageデザインのバリエーション

無効中止と有効中止

有効中止は必要か？

	Flemingの方法 1982	Simonの方法 1989	SWOGの方法 1992
無効中止の考慮	✓	✓	✓
有効中止の考慮	✓		

- 利用されている多くの2-stage designは無効中止のみ考慮
- その理由は？

2-stageデザインの場合の α エラー

真実は効果がない場合

2-stageデザインの場合の β エラー

真実は効果がある場合

2-stageデザインのサンプルサイズの決め方

- α と β が条件を満たすサンプルサイズ (N) は複数パターンある
  - $\alpha=5\%$ を固定しながら、 $\beta=20\%$ を設定すると、
(実際は条件付き確率でもう少し複雑だがイメージのため単純化)
    - 第1段階で $\beta=5\%$ なら、第2段階は $\beta=15\%$
      - 第1段階で β が小さい = 第1段階で多くのNが必要
    - 第1段階で $\beta=15\%$ なら、第2段階は $\beta=5\%$
      - 第1段階で β が大きい = 第1段階で相対的に少ないNが良い
- α と β が条件を満たすNの中から、何かしらの規準に従ってN(N1,N2)を設定する必要がある
  - 真の奏効割合が p_0 の時に期待されるNを最小にしたい
  - 真の奏効割合が p_1 の時に登録されるNを最小に
  - . . .

Simonの2-stageデザイン

- **無効中止のみ**考慮したデザイン
  - 一定以上の奏効例が得られているかどうかで有効/無効を判断
- サンプルサイズの決め方は2通りの規準を提案
  - **Optimal design**
    - 帰無仮説が正しい時に**期待症例数**を最小にする
  - **Minimax design**
    - 特定の試験に登録される**最大症例数**を最小にする

例 : $\alpha=5\%$, 検出力=80%

閾値=20%,期待値=40%	Optimal	Minimax
1 st stageの患者数	13	18
奏効例がこれ以下なら無効中止	3 (23%)	4 (22%)
2 nd stageまでの総患者数	43	33
奏効例がこれ以下なら無効	12 (28%)	10 (30%)
帰無仮説が真値の場合の期待患者数	20.6	22.3
帰無仮説が真値の場合に無効中止になる確率	75%	72%

閾値=5%,期待値=20%	Optimal	Minimax
1 st stageの患者数	10	13
奏効例がこれ以下なら無効中止	0 (0%)	0 (0%)
2 nd stageまでの総患者数	29	27
奏効例がこれ以下なら無効	3 (10%)	3 (11%)
帰無仮説が真値の場合の期待患者数	17.6	19.8
帰無仮説が真値の場合に無効中止になる確率	60%	51%

サンプルサイズは Optimal > Minimaxとなる

Simonの2-stageデザインの欠点

- 第1段階,第2段階ともに患者が予定通りに登録される前提
- 多施設研究でそこまで正確に登録数を管理できるか？
  - 登録終了のアナウンスをしてもIC取得済みの患者は登録
  - 後から不適格例がわかったらどうする？
    - CRFが集まってから始めてわかる
    - 既に登録が終了していても、また登録再開？
- もし実際の解析対象数（全適格例）が変わると、設定している α 、 β を保てなくなることがある
  - 無効中止、positiveの判断に必要な奏効例数はサンプルサイズ計算時の必要解析対象者数で規定
  - 別途、計算が必要となる

より現場のオペレーションに合ったデザインが必要

SWOGの2-stageデザイン

- 無効中止のみを考慮したデザイン
  - 第1段階は $\alpha=2\%$ で無効中止の検討
(期待値 p_1 を帰無仮説とした検定)
    - おおよそ奏効割合が p_0 未満の時に無効中止になる
  - 第2段階は $\alpha=5.5\%$ で検定
    - 有意ならPhase IIIへ
    - おおよそ奏効割合が $(p_0+p_1)/2$ を超えると有意になる
- 利点
  - 実際の解析対象数が予定と比べて増減してもOK
    - 検定で判断する ($p < \alpha$ かどうか) ので柔軟に対応可

<http://www.swogstat.org/stat/public/twostage.htm>

Green, S et al., *Statistics in medicine* 11.7 (1992): 853-862.

ICRweb 臨床研究入門 www.icrweb.jp

各方法のサンプルサイズと判断規準

	P0 vs P1	第1段階登録数	1段階目で無効	1段階目で有効	第2段階登録数	2段階目で無効	2段階目で有効	実質alpha	実施power
Simon	5% vs 20%	29	1	-	38	4	5	3.9%	90%
(Minimax)	10% vs 30%	22	2	-	33	6	7	4.1%	90%
	20% vs 40%	24	5	-	45	13	14	4.8%	90%
	30% vs 50%	24	7	-	53	21	22	4.7%	90%
SWOG	5% vs 20%	20	0	-	40	4	5	4.7%	92%
	10% vs 30%	20	1	-	35	7	8	2.0%	87%
	20% vs 40%	25	4	-	45	13	14	5.2%	91%
	30% vs 50%	30	8	-	55	22	23	4.1%	91%

実際にどれを使うのか？

- 3段階以上のデザインは？
- 1段階と2段階の使い訳は？
- 2段階の中では？

実際に多く使われているのは？：文献①

- 2010-2015年のJCO, Ann Oncol, BJC の phase 2 を調査
- Single armの**315**件中
  - 1-stage : **167**件(53%)
  - 2-stage : **146**件(46%)
    - SimonのOptimal : 47
    - Simonのmini-max : 21
    - SimonのOptimal or mini-max : 33
    - SWOG : 4
    - Fleming : 1
  - 3-stage以上 : 2件

実際に多く使われているのは？：文献②

2005,2010,2014年のJCO, Ann Oncol, Cancer, CCR, Lancet Onc, NEJM, Lancetの phase 2 を調査

Table 4. Statistical design and number of patients per arm.

	2005 (n = 141)	2010 (n = 150)	2014 (n = 56)	Total (n = 347)
Multi-arm	50 (35%)	51 (34%)	28 (50%)	129 (37%)
Randomized				
Yes	31 (62%)	34 (67%)	23 (82%)	88 (25%)
No	19 (38%)	17 (33%)	5 (18%)	38 (11%)
Comparative				
Yes	20 (40%)	17 (33%)	9 (32%)	46 (36%)
No	30 (60%)	34 (67%)	19 (68%)	83 (64%)
Single arm	91 (65%)	99 (66%)	28 (50%)	218 (63%)
Statistical design				
Single stage	41 (45%)	44 (44%)	10 (36%)	95 (44%)
Simon	39 (43%)	35 (35%)	13 (46%)	87 (40%)
Fleming	2 (2%)	7 (7%)	3 (11%)	12 (6%)
Bayesian	1 (1%)	6 (6%)	0 (0%)	7 (3%)
Gehan	5 (6%)	1 (1%)	1 (3%)	7 (3%)
Flexible	0 (0%)	3 (3%)	0 (0%)	3 (1%)
Bryant & Day	2 (2%)	1 (1%)	0 (0%)	3 (1%)
Sargent	0 (0%)	2 (2%)	0 (0%)	2 (1%)
London	0 (0%)	0 (0%)	1 (4%)	1 (0%)
Triangular test	1 (1%)	0 (0%)	0 (0%)	1 (0%)

1-stageとSimonの方法が主流

Ivanova A, Paul B, Marchenko O, et al: J Biopharm Stat 26:141-9, 2016

1-stage ? 2-stage ?

- TAPUR (Targeted Agent and Profiling Utilization Registry)
  - FDAで承認済みのoff-label の薬剤を評価する試験
  - 解析対象は、ある薬剤を投与された、特定の原発巣で、特定の遺伝子変異を持つ患者

- NCI-MATCH (Molecular Analysis for Therapy Choice)
  - 特定の遺伝子変異に対する薬剤の評価をする試験
  - 解析対象は、ある薬剤を投与された、~~特定の原発巣で、~~特定の遺伝子変異を持つ患者

Simon R: Ann Intern Med 165:270-8, 2016

Mangat PK, Halabi S, Bruinooge SS, et al: JCO Precision Oncology:1-14, 2018

使いわけの考え方（決まったルールはない）

- 3段階以上のデザイン：ほぼ使われていない
  - 奏効有無判明までの期間の患者登録停止期間の無駄
    - ただしEDCの導入により以前よりはデメリットが小さくなりつつある
- 1-stage：有効性がわかっている薬剤の時に正当化される
  - 特定がん種に対する既承認薬の組み合わせなど
- 2-stage：1-stageで行う理由が説明しにくい場合
  - 倫理的配慮で無効中止を考慮
  - 有効中止の考慮は不要
    - 効果あるなら倫理的問題は生じない/有効性・安全性の情報の蓄積
- Simonの Optimal vs Minimax vs SWOG
  - 試験実施組織として複数試験全体でのNを抑えたいならoptimal
  - 1試験の事だけならminimax
  - 多施設で対象者数がコントロールしにくいならSWOGも選択肢

補足

サンプルサイズとpositiveとなる奏効数

あるコンセプト検討会での出来事

閾値=5%、期待値=30%、片側 α =5%、検出力=80%で計算したところ必要解析対象者数は14例でした。若干の不適合例を見込んで予定登録数を17例としました

それでも良いのですが、 $N=17$ とすると検出力=80%が担保できません。18例以上にするか、 $N=16$ にしておいた方が良いかもしれません。

え？なんで $N=14$ よりも増やしているのに検出力が落ちるんですか？何をおっしゃっているのかわかりません……。

復習： α エラーと β エラー

		真実	
		効果なし（閾値）	効果あり（期待値）
検定結果	有意差なし	正しい	誤り (β エラー)
	有意差あり	誤り (α エラー)	正しい (検出力 $1-\beta$)

- α と β は同時に小さくすることはできない
- 同時に小さくしたければNを増やす必要あり

閾値5%でN=14例の時に得られる奏効例数の確率

3例以上の奏効でpositiveと判断すれば $\alpha < 5\%$ となる

期待値30%でN=14例の時に得られる奏効例数の確率

3例以上の奏効でpositiveと判断すれば検出力 > 80%となる

同様に各Nの条件で計算する

$\alpha=5\%$ を満たす条件での検出力

N	Positiveとなる 奏効例数 (奏効割合)	実際の α	実際の 検出力
13	3 (23%)	2.5%	79.8%
14	3 (21%)	3.0%	83.9%
15	3 (20%)	3.6%	87.3%
16	3 (19%)	4.3%	90.1%
<u>17</u>	<u>4 (24%)</u>	<u>0.9%</u>	<u>79.8%</u>
18	4 (22%)	1.1%	83.5%
19	4 (21%)	1.3%	86.7%
20	4 (20%)	1.6%	89.2%

13例以下では検出力80%を
担保できない

Nを増やすと、 $\alpha < 5\%$ を満たしながら
Positiveとなる奏効例数のハードルが
高くなり、powerが落ちる場合がある

質問：必要解析対象数の設定は？

N	Positiveとなる 奏効例数 (奏効割合)	実際の α	実際の 検出力
13	3 (23%)	2.5%	79.8%
14	3 (21%)	3.0%	83.9%
15	3 (20%)	3.6%	87.3%
16	3 (19%)	4.3%	90.1%
<u>17</u>	<u>4 (24%)</u>	<u>0.9%</u>	<u>79.8%</u>
18	4 (22%)	1.1%	83.5%
19	4 (21%)	1.3%	86.7%
20	4 (20%)	1.6%	89.2%

① 14例

② 16例

③ 15例

④ 17例

⑤ 18例

⑥ 19例

⑦ 20例

まとめ

- 閾値と期待値の意味
- P値と信頼区間の関係
- 1-stage と 2-stageデザインの使いわけ
- Simonのminimaxとoptimalの違い
- Nを増やしてもpowerが減る理由

Appendix

単群の割合をエンドポイントとした試験： SWOGのwebsiteの場合

- SWOGのwebsite「<https://stattools.crab.org/>」

[One Arm Binomial]を選ぶ

生存割合の場合
[One Arm Non-Parametric Survival]を選んでも良い

Design	Analysis
One Arm Binomial	Frequency Table
One Arm Survival	Binomial Confidence Interval
One Arm Normal	Probabilities
One Arm Non-Parametric Survival	Normal
Two Stage	Binomial
Two Arm Binomial	Poisson
Two Arm Survival	Chi-Square
Two Arm Normal	

One Arm Binomial

- 片側 $\alpha=10\%$, 検出力=80%, 閾値=20%, 期待値=40%の場合

User Input		Program Output	
Select Calculation and Test Type			
☒ Sample Size ☐ Power		☒ 1 Sided ☐ 2 Sided	
Select Hypothesis Test Parameters			
Null Proportion	Alternative Proportion	Alpha	
0.2	0.4	.1	
Calculate Power/Sample Size			
Power	Sample Size		
.80			
Approx Lower Count Critical Value			
Approx Upper Count Critical Value			
Calculate Exact Alpha/Power			
Exact Alpha Level		Exact Power	

Power	Sample Size
.80	24
Approx Lower Count Critical Value	
-1	
Approx Upper Count Critical Value	
8	
Calculate Exact Alpha/Power	
Exact Alpha Level	Exact Power
0.0892	0.8081

注意事項 :

- ・ 計算法により値は少しずつ変わる
- ・ 厳密には、検定の時に用いる方法により、適切な計算法も変わる

One Arm Nonparametric Survival

- 片側 $\alpha=10\%$, 検出力 $=80\%$, 1年OS閾値 $=20\%$, 1年OS期待値 $=40\%$

の場合

User Input		Program Output	
Select Calculation, Test type and Parameter of Interest			
☒ Sample Size	☒ 1 Sided	☐ Median Survival	
☐ Power	☐ 2 Sided	☒ Survival Probability	
Select Study and Hypothesis Test Parameters			
Accrual Time 2	Follow-up Time 1	Alpha .1	
Null Median Survival	Null Survival Prob 0.2		
Alt Median Survival	Alt Survival Prob 0.4		
	At Time 1		
Power .80	Size	Approx Lower Critical Value	Approx Upper Critical Value

Sample Size	Approx Lower Critical Value	Approx Upper Critical Value
23	0	0.34

1年割合が34%以上で positive

注意事項：
・ KM法で生存割合を算出する前提

- 登録期間：実際に登録できそうな期間でOK
- 追跡期間：エンドポイントに設定している期間よりも長ければOK（今回なら1年以上）

単群の割合をエンドポイントとした試験： ICRwebアプリの場合

割合の閾値・期待値

- 片側 $\alpha=10\%$, 検出力=80%, 閾値=20%, 期待値=40%の場合

割合の閾値・期待値 TOPへ

閾値割合: 0.2 閾値

期待値割合: 0.4 期待値

片側 α (有意水準): 0.1 $\alpha=10\%$

検出力: 0.8 検出力=80%

サンプルサイズ最小値: 5

サンプルサイズ最大値: 50

- サンプルサイズ最小値: 適当に値を設定
- サンプルサイズ最大値: 実施可能な最大のNを入れておく

検出力を共に満たすパターン一覧

(閾値割合: 0.2 期待値割合: 0.4 片側有意水準: 0.1 検出力: 0.8)

項番	必要例数	この値以上ならpositive	実質 α	実質power
1	24	8		
2	27	9		
3	28	9		
4	30	10	0.061087	0.823714
5	31	10	0.074600	0.856624
6	32	10	0.089832	0.884448
7	33	11	0.050837	0.831026
8	34	11	0.062027	0.861685
9	35	11		
10	36	11		
11	37	12		
12	38	12	0.062309	0.891120
13	39	12	0.074226	0.911782
14	40	12	0.087505	0.929051
15	41	13	0.052094	0.894514
16	42	13	0.062107	0.914045
17	43	13	0.073321	0.930451

30例以上であれば、
確実に検出力 $\geq 80\%$

「必要例数」の数値の抜けが
なくなる最小の値を選ぶ

補足 :

- Nが多めになる手法を採用しているので、実施可能ならこの方法を用いればOK
- Nが多すぎたり、最小値~最大値の範囲が広いと計算時間がかかる