

シンビオ社会研究会令和7年度研究談話会 (2026/1/22)

AI技術を応用した、ヘリオトロン水冷却系
のアベイラビリティ解析の高度化

令和8年1月22日

松岡 猛 (宇都宮大学)

mats@cc.utsunomiya-u.ac.jp

松岡 猛 (宇都宮大学)

本報告の内容

令和7年度京大エネルギー理工学研究所ゼロエミッション研究拠点 ZE 共同研究 (ZE2025N-02) として、GO-FLOW 解析法を用いて水冷却系のアベイラビリティ解析を実施している。

この共同研究では別途高調波診断技術を用いた電気設備の診断及びAI技術の活用の研究も進めている。

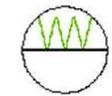
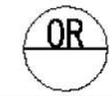
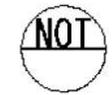
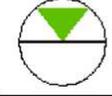
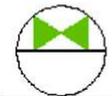
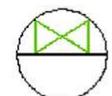
それらの知見をGO-FLOW解析に反映し、アベイラビリティ解析をより高度化し、保守点検方法への反映について検討した結果について報告する。

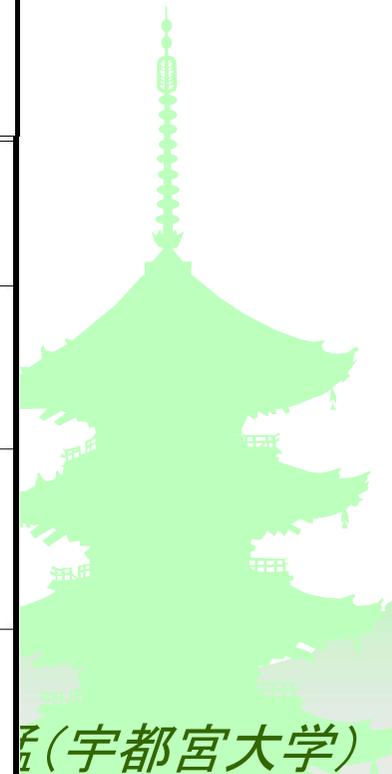
GO-FLOW手法の紹介

- 松岡によって開発された成功確率を追うシステム信頼性解析手法
- システムを構成する機器を標準のオペレータでモデル化
- 機器の接続関係を信号線により表現し、GO-FLOWチャートを作成する
- GO-FLOWチャートとシステムのフロー・ダイアグラムが対応。

GO-FLOWオペレータ

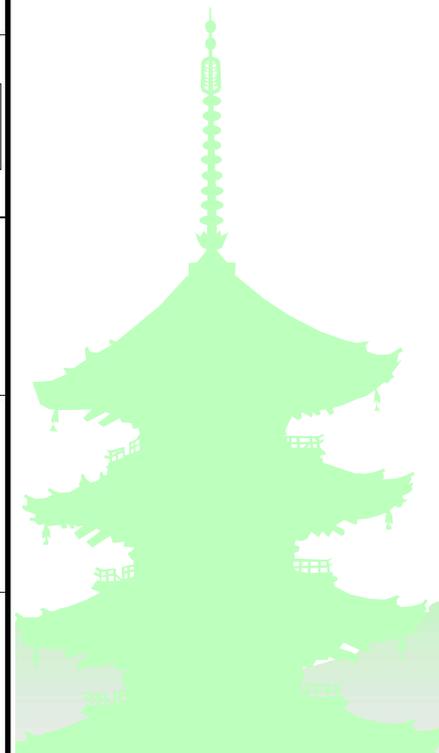
Table 2. Operators of the GO-FLOW methodology

Type	Shape	Main inputs	Sub inputs	Output
Description				
21		$S(t)$	—	$R(t) = S(t) \cdot P_g$
Two state operator				
22		$S_1(t), S_2(t)$ $\dots S_n(t)$	—	$R(t) = 1.0 - \prod_{i=1}^n [1.0 - S_i(t)]$
OR gate				
23		$S(t)$	—	$R(t) = 1.0 - S(t)$
NOT gate				
24		$S(t)$	—	$R(t) = 1.0 - S(t')$ $R(t_1) = 0.0$
Difference operator				
25		—	—	$S(t) \text{ or } P(t)$
Signal generator				
26		$S(t)$	$P(t)$	$R(t) = S(t) \cdot O(t), O(t_1) = P_p$ $O(t) = O(t') + [1.0 - O(t')] \cdot P(t) \cdot P_g$
Closed state operator				
27		$S(t)$	$P(t)$	$R(t) = S(t) \cdot O(t), O(t_1) = 1.0 - P_p$ $O(t) = O(t') \cdot [1.0 - P(t) \cdot P_g]$
Open state operator				



GO-FLOWオペレータ(続き)

28		$S(t)$	-	$R(t) = S(t-k); (t-k) > 0$ $R(t) = S(t_1); (t-k) \leq 0$
Delay operator				
30		$S_1(t), S_2(t)$ $\dots S_n(t)$	-	$R(t) = \prod_{i=1}^n S_i(t)$
AND gate				
35		$S(t_1), S(t_2)$ $\dots S(t_n)$	$P_1(t_1), P_1(t_2) \dots P_1(t_n); P_2(t_1), P_2(t_2) \dots P_2(t_n); \dots$	$R(t) = S(t) \left[\frac{\mu}{\lambda + \mu} + \frac{\lambda}{\lambda + \mu} \exp \left\{ -(\lambda + \mu) \sum_i \sum_{t_k \leq t} P_i(t_k) \min \left[1.0, \frac{S(t_k)}{S(t)} \right] \right\} \right]$
Aging work operator				
37		$S(t)$	$P_1(t_1), P_1(t_2) \dots P_1(t_n)$ $P_2(t_1), P_2(t_2) \dots P_2(t_n)$ \dots	$R(t) = S(t) \left[\frac{\mu}{\lambda + \mu} + \frac{\lambda}{\lambda + \mu} \exp \left\{ -(\lambda + \mu) \sum_i \sum_{t_k \leq t} P_i(t_k) \right\} \right]$
Aging open state operator				
38		$S(t)$	$P_1(t_1), P_1(t_2) \dots P_1(t_n)$ $P_2(t_1), P_2(t_2) \dots P_2(t_n)$ \dots	$R(t) = S(t) \left[1.0 - \frac{\mu}{\lambda + \mu} - \frac{\lambda}{\lambda + \mu} \exp \left\{ -(\lambda + \mu) \sum_i \sum_{t_k \leq t} P_i(t_k) \right\} \right]$
Aging closed state operator				
39		$S(t)$	$P_1(t)$ $P_2(t)$	$R(t) = S(t) \cdot O(t), O(t_1) = P_p$ $O(t) = O(t') + [1.0 - O(t')] \cdot P_1(t) \cdot P_o$ $O(t) = O(t') \cdot [1.0 - P_2(t) \cdot P_c]$
Open/Close action operator				
40		$S(t)$	-	$R(t) = 1.0; (t < t_i)$ $R(t) = S(t); (t_i \leq t \leq t_j)$ $R(t) = S(t_j); (t_j < t)$
Phased mission operator				



GO-FLOWオペレータ(定義式内の記号の意味)

In this Figure,

$S(t)$ = main input signal S at time point t,

$P(t)$ = sub input signal at time point t,

$R(t)$ = output signal at time point t,

$O(t)$ = probability for valve in open state at time point t,

t' = time point immediately before the time point t,

t_i, t_j = start time point and end time point of a specific phase,

k = number of time points delayed,

P_g = probability for successful operation,

P_p = probability for premature operation,

P_o = probability for valve successful open,

P_c = probability for valve successfully close,

λ = failure rate of a component,

μ = recovery rate of a component.

解析の手順

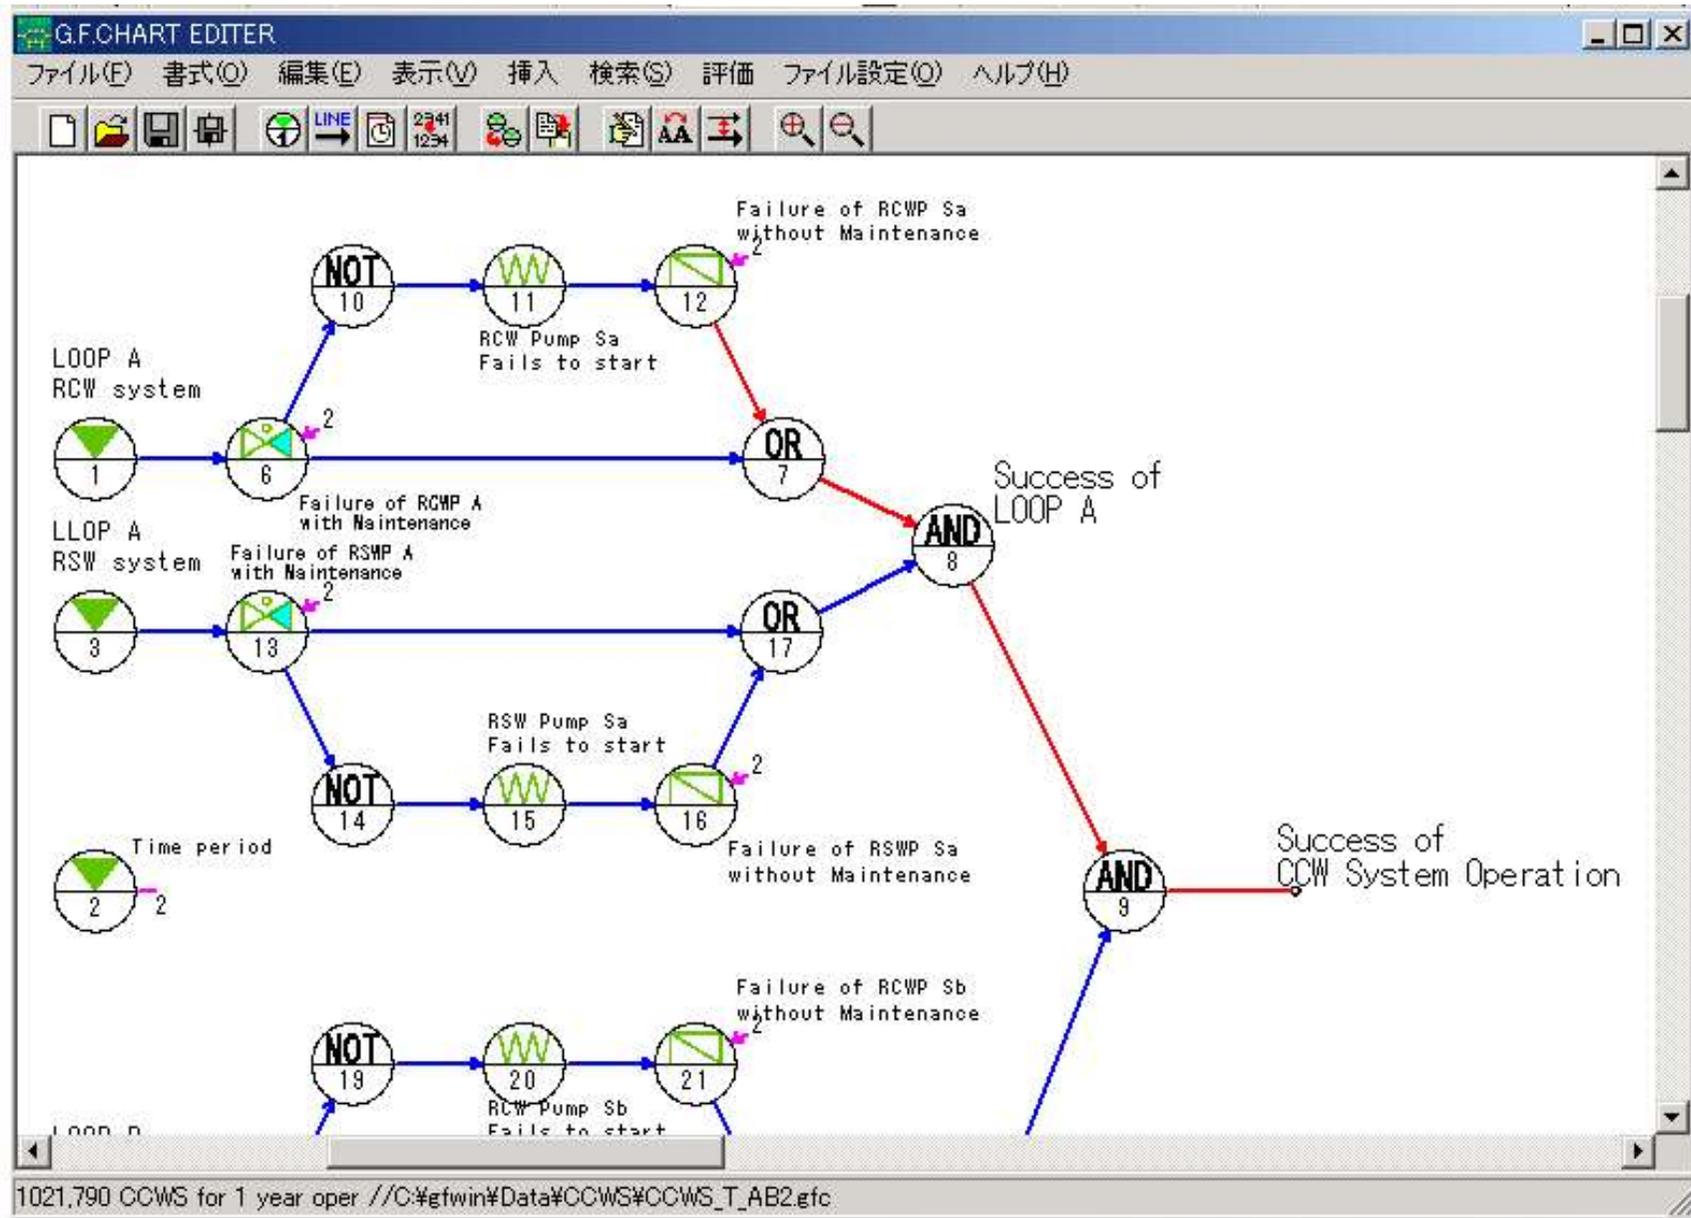
- GO-FLOWチャートの作成
- 時間推移による状態変化を記述するためタイム・ポイントを定義
- 故障率データ、機器動作タイミング等の割り付け
- 解析プログラムの実行(チャート作成ツールの1つのメニューとなっている)
- 解析結果まとめ



GO-FLOW手法でできること

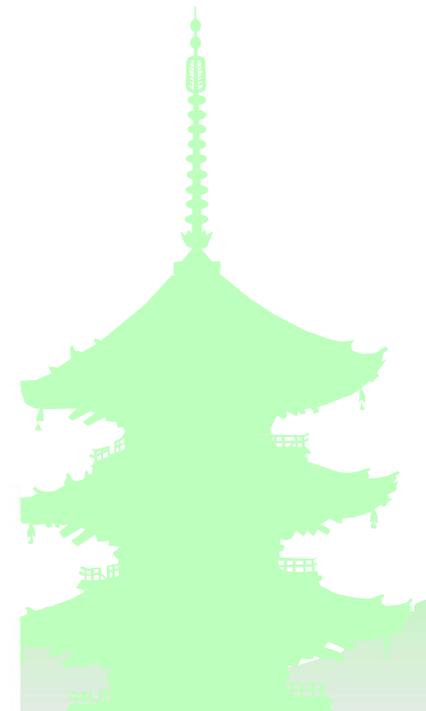
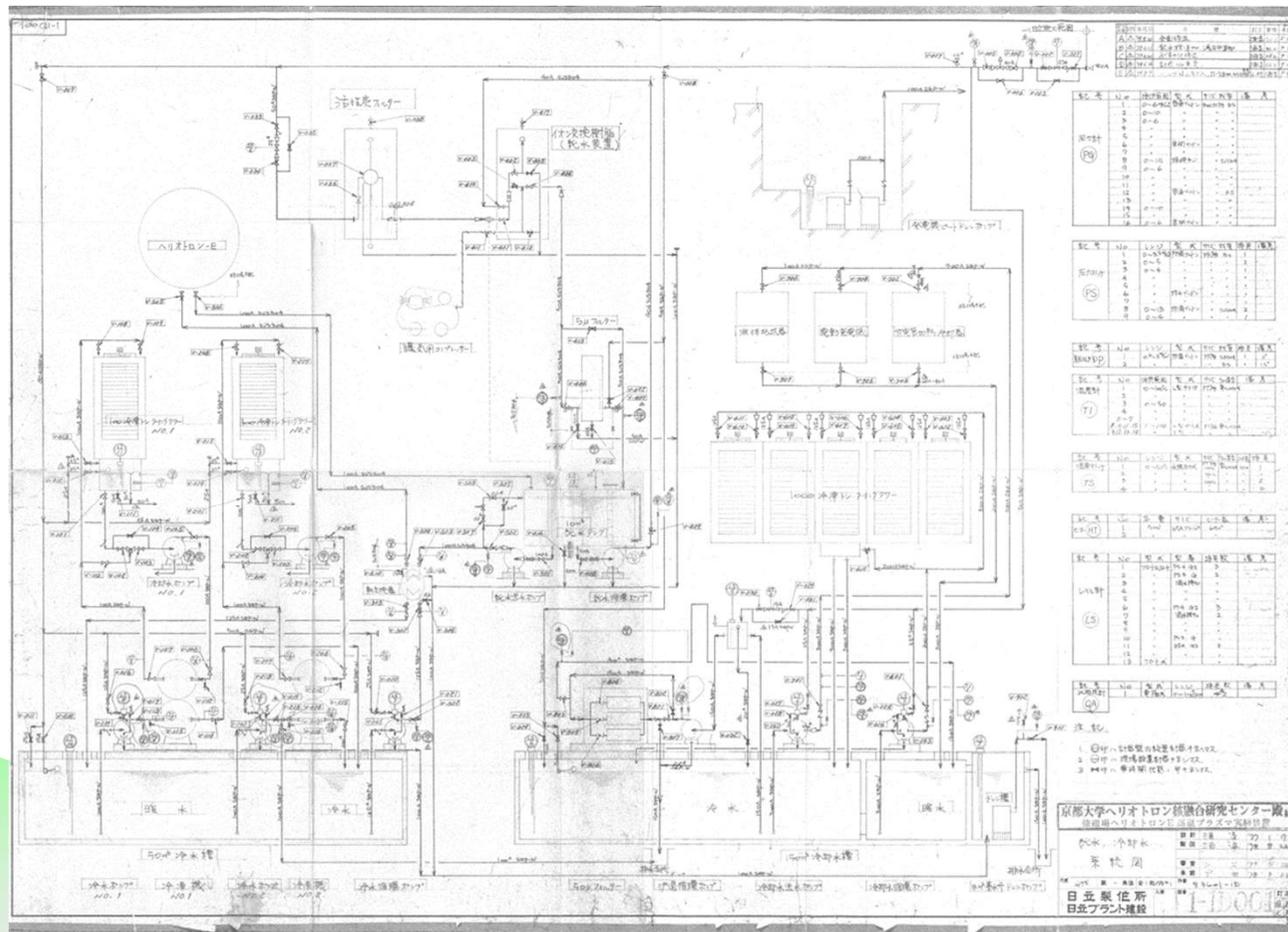
- 基本解析機能 ➡ 保守・点検によるアベイラビリティの推移。
- 不確実さ解析
- 一つの原因で同時に多数の機器が故障する共通原因故障解析
- 共通原因故障を考慮した不確実さ解析
- システムの動的挙動の解析が容易
- システムに要求される使命が段階を追って変化するフェイズド・ミッション問題の解析が容易

GO-FLOW chart editor

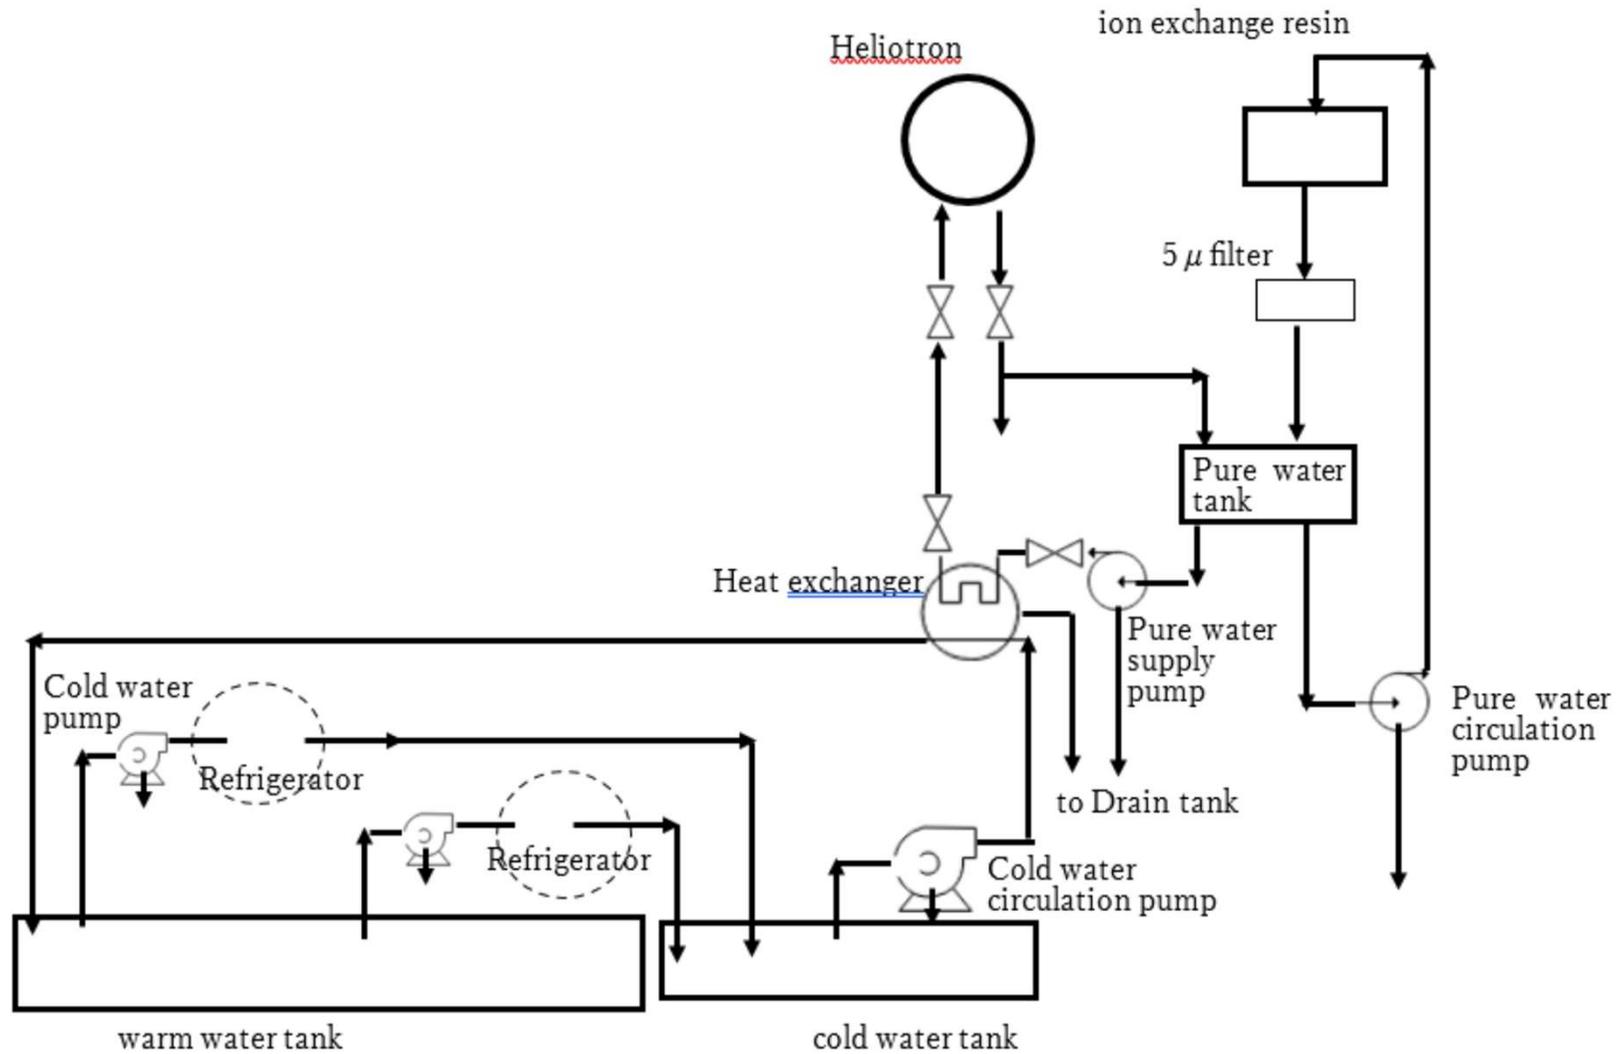


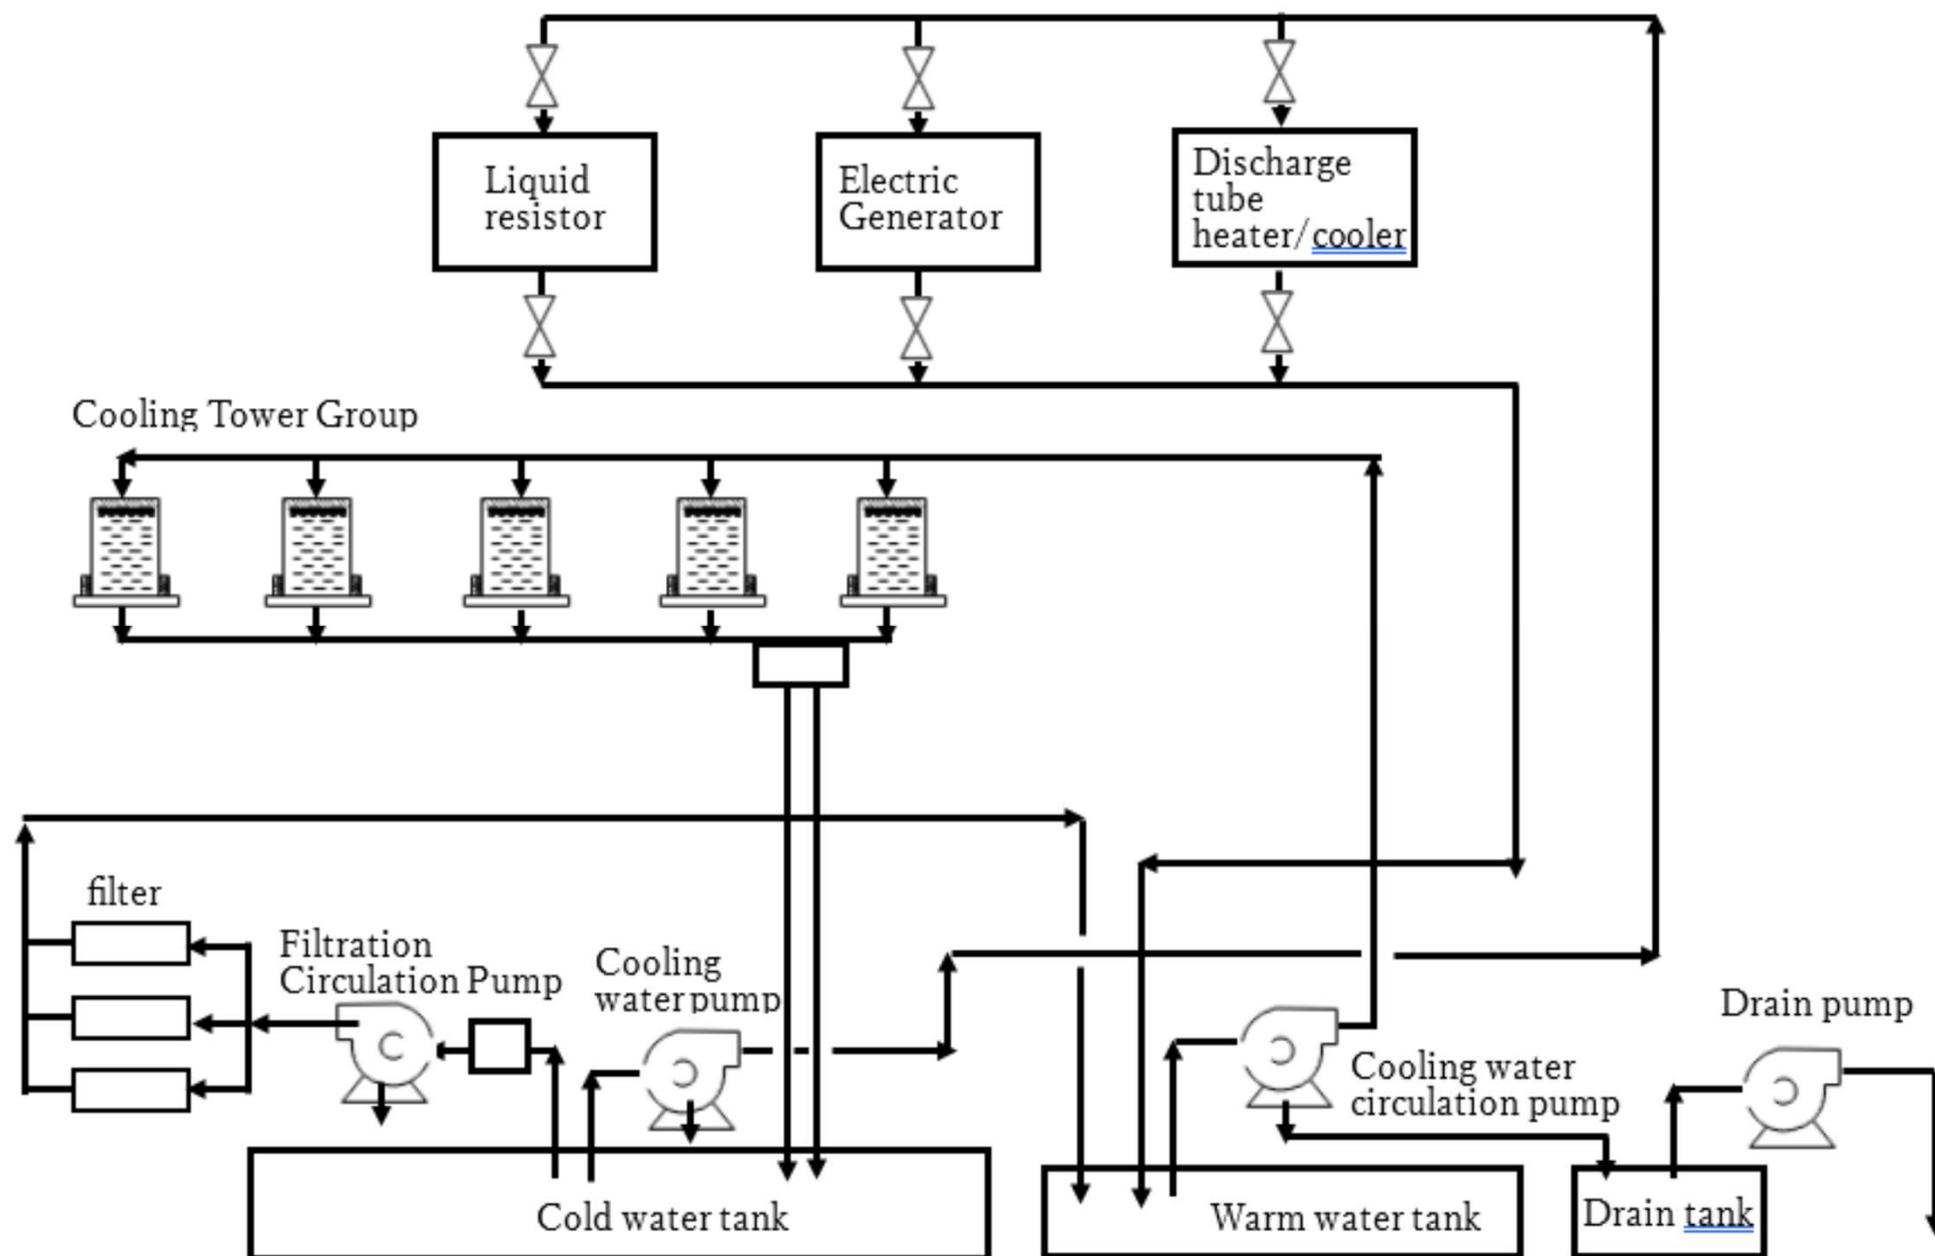
アベイラビリティ解析の実施

ヘリオトロン-J冷却システムの図面

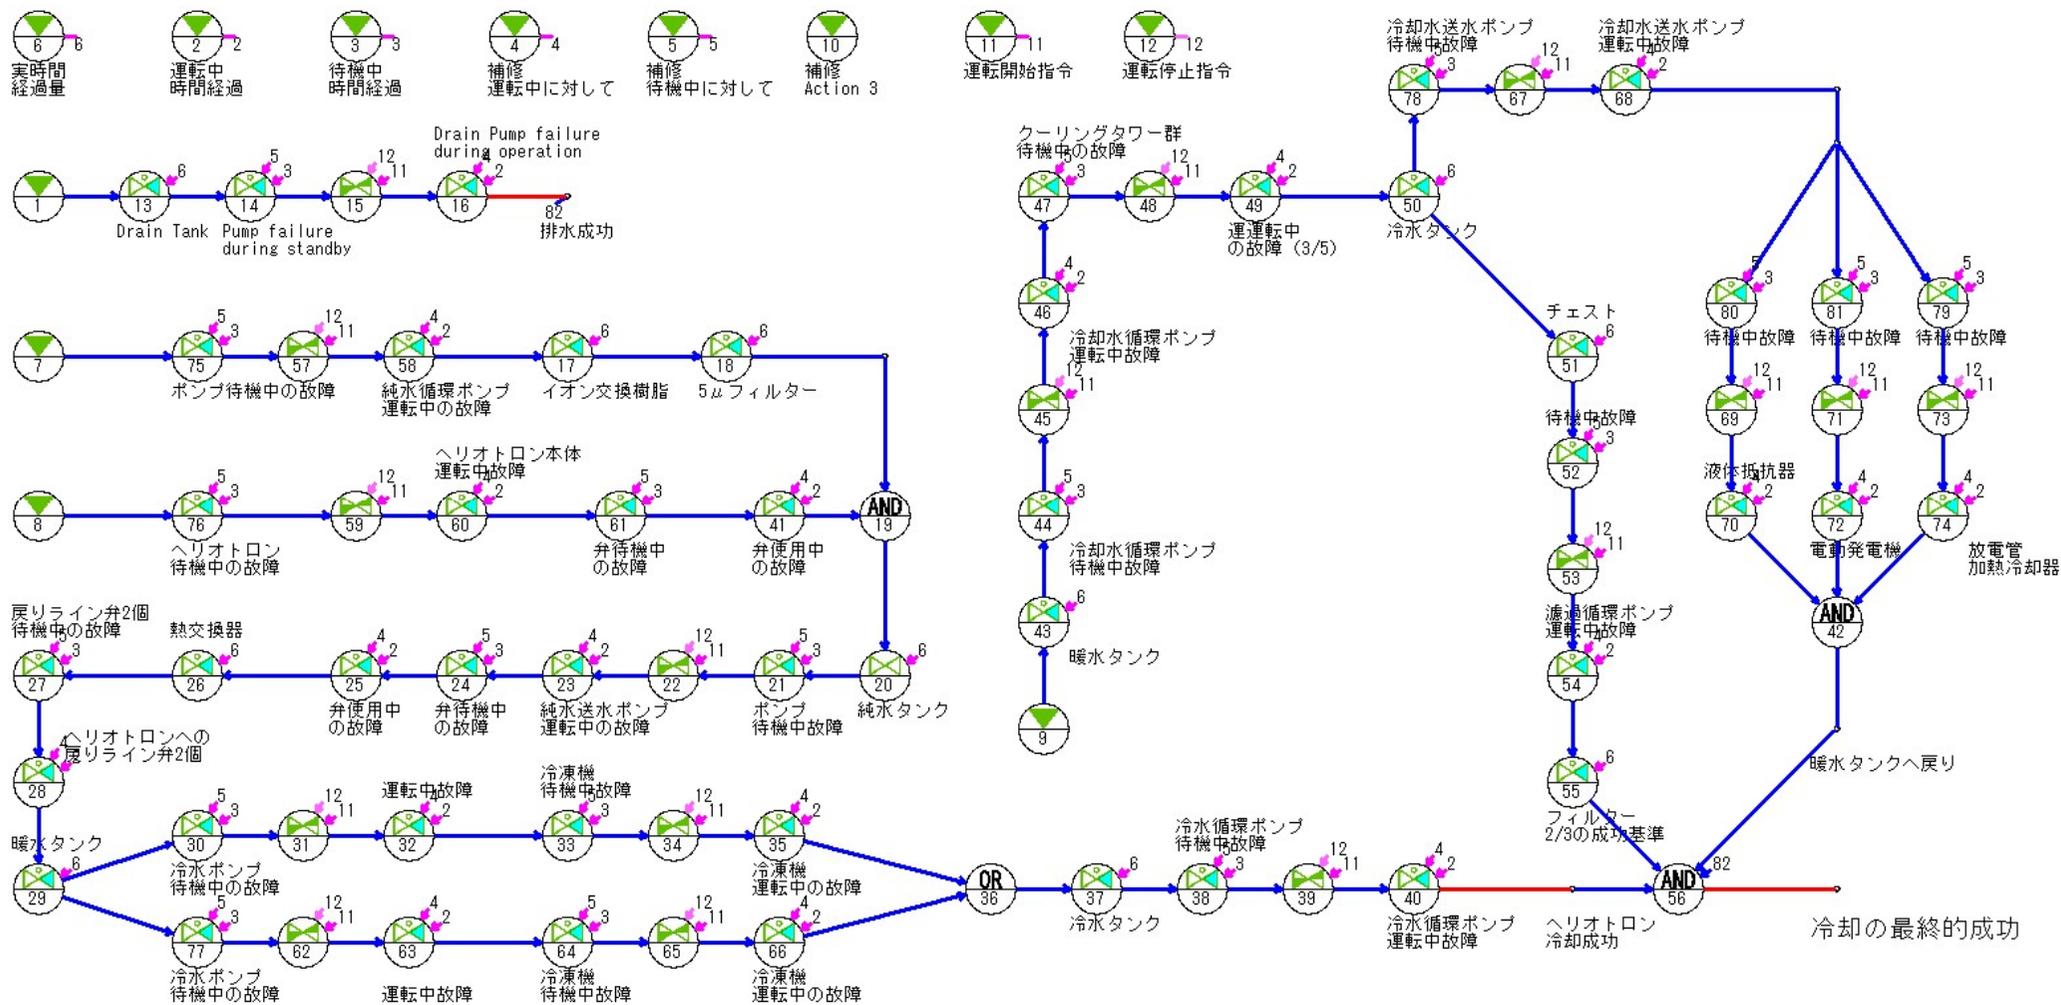


システムのフロー図





作成されたGO-FLOWチャート



保守条件のケースA~D

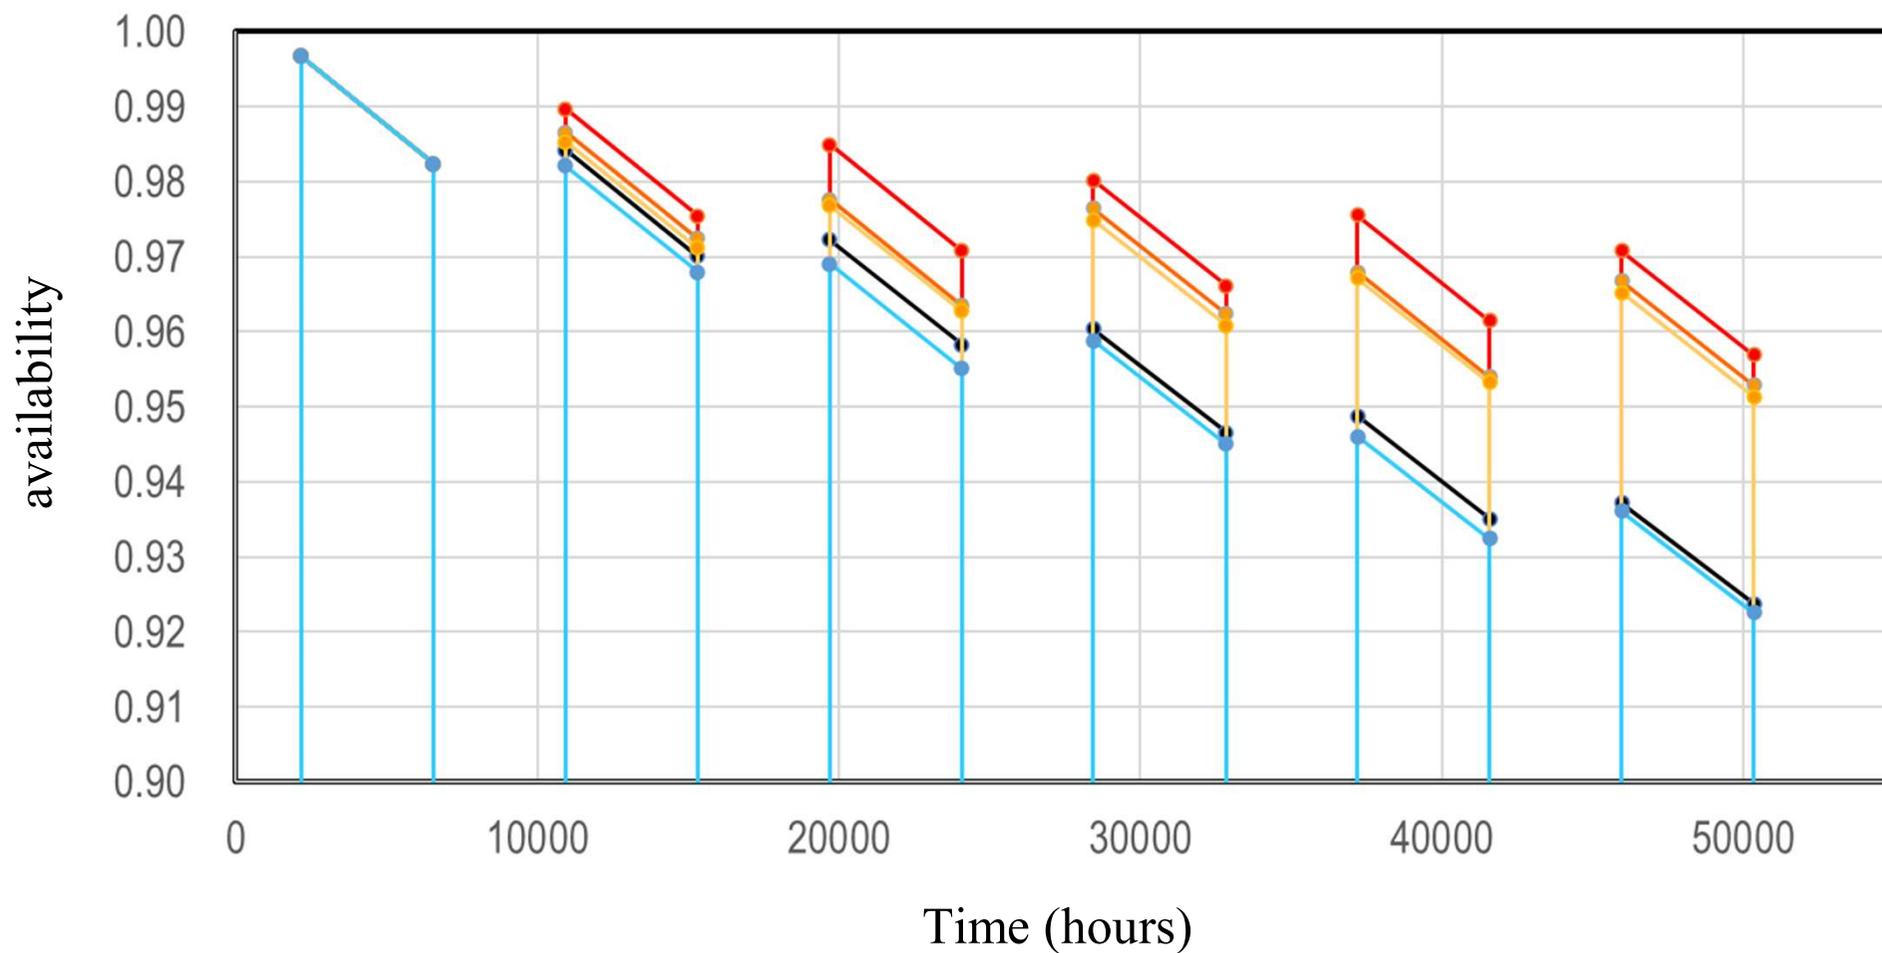
Table 2. Repair actions for the components.

Components	Failure mode	Base case	Case A	Case B	Case C	Case D
Heliotron main part	Operating failure	O	O	O	O	O
	Standby failure	O	O	O	O	O
Pump	Operating failure	O	O	(O)	(O)	(O)
	Standby failure	-	O	(O)	(O)	-
Refrigerator	Operating failure	O	O	O	(O)	(O)
	Standby failure	-	O	O	(O)	-
Liquid resistor	Operating failure	O	O	(O)	(O)	(O)
	Standby failure	-	O	(O)	(O)	-
Electric Generator	Operating failure	O	O	O	(O)	(O)
	Standby failure	-	O	O	(O)	-
Discharge tube heater/cooler	Operating failure	O	O	(O)	(O)	(O)
	Standby failure	-	-	-	-	-
Valve	Operating failure	-	O	(O)	(O)	-
	Standby failure	-	-	-	-	-
Cooling Tower	Operating failure	O	O	O	O	O
	Standby failure	-	O	O	-	-
Filter	Standby failure	O	O	O	O	O
Tank and other components	Deterioration over time (aging)	-	-	-	-	-

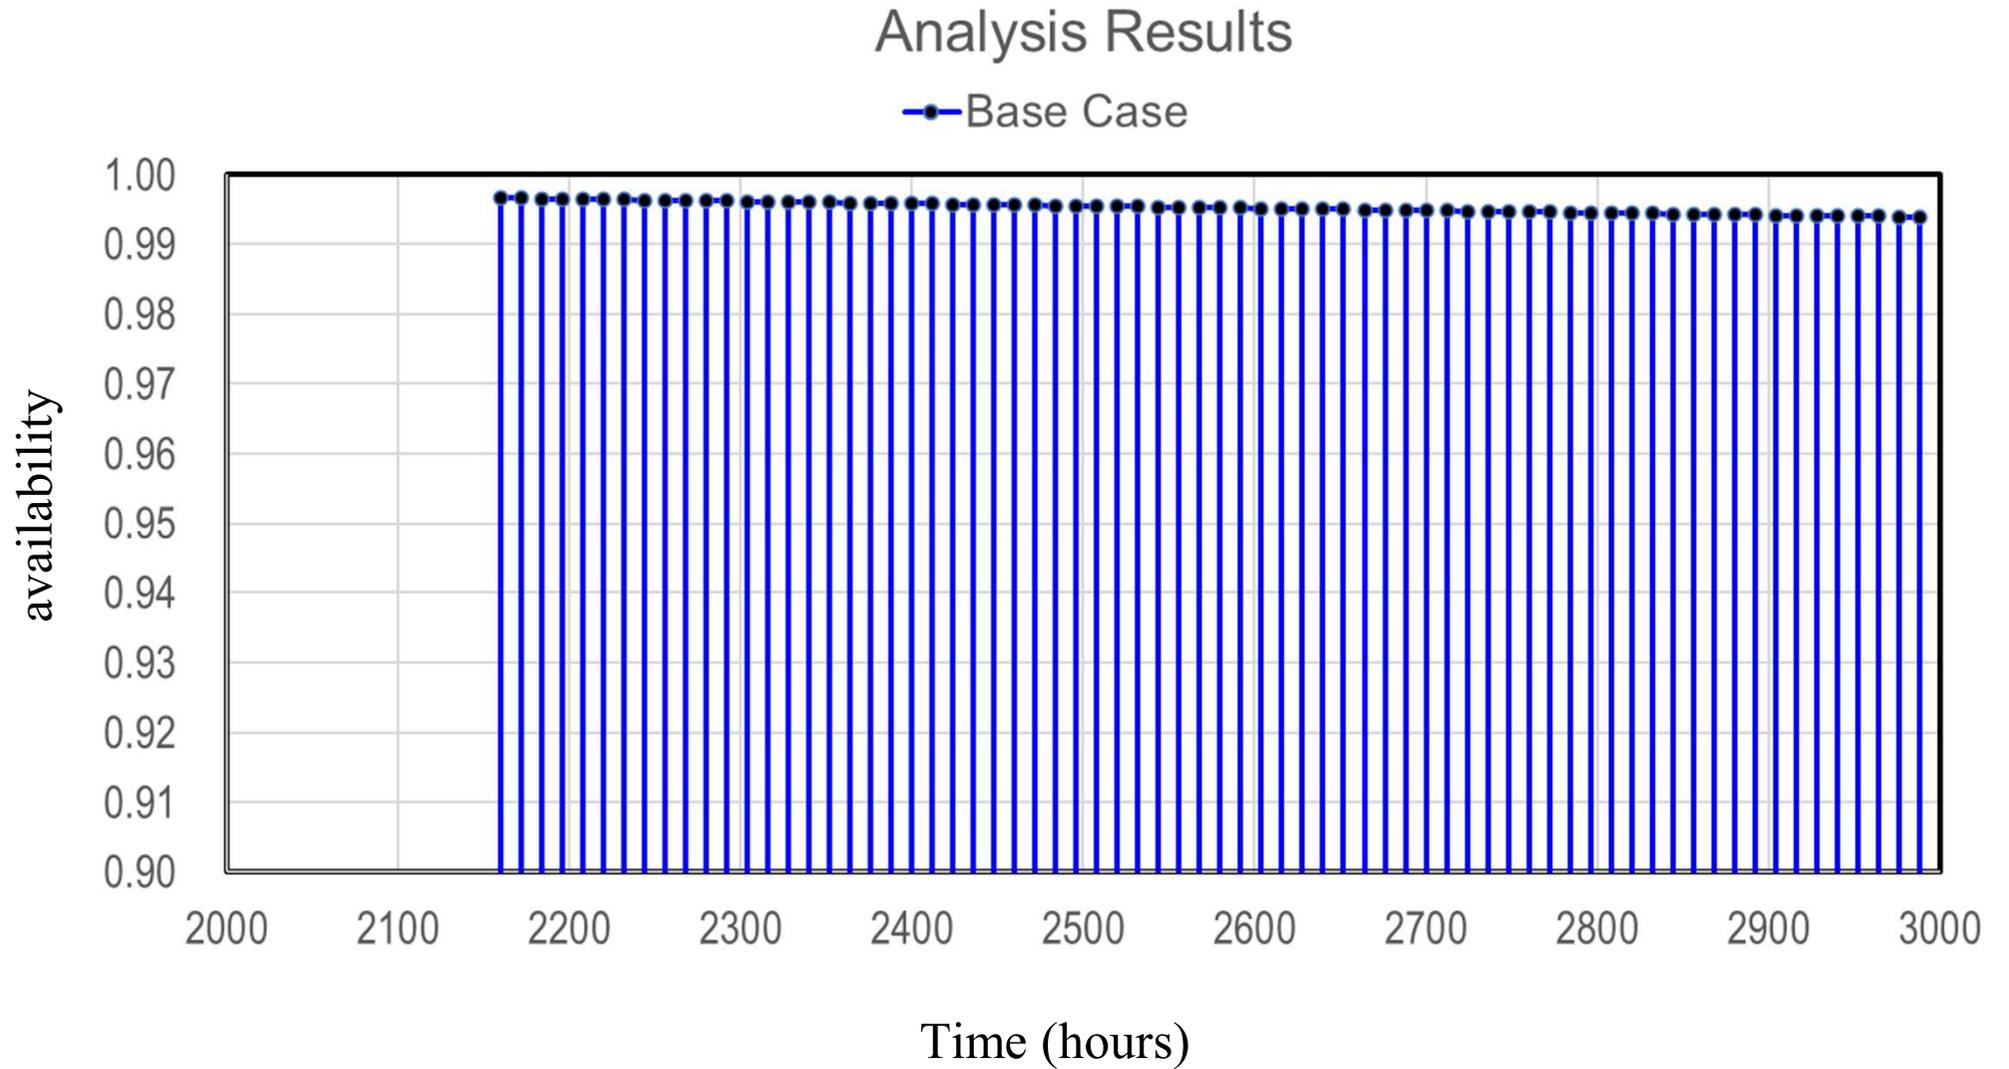
アベイラビリティ解析結果

Analysis Results

● Base Case ● Case A ● Case B ● Case C ● Case D



(注意) 実際のアベイラビリティの推移



点検・保守の効果の考慮方法(現状)

- ◆ ヘリオトロン本体以外ほぼすべての機器について点検・保守を隔年に実施する。
- ◆ 各機器について**運転中故障**と**待機中故障**の2種類の故障モードを考慮する。
- ◆ **点検**しただけでは機器状態の条件は変更しない。
- ◆ **保守**を実施した後、**機器は新品と同様**となるとする。→**経過時間をリセットする(ゼロとする)**。
- ◆ **簡略な保守**→**運転中故障のみ**リセット
- ◆ **丁寧な保守**→**待機中故障と運転中故障双方**をリセット。

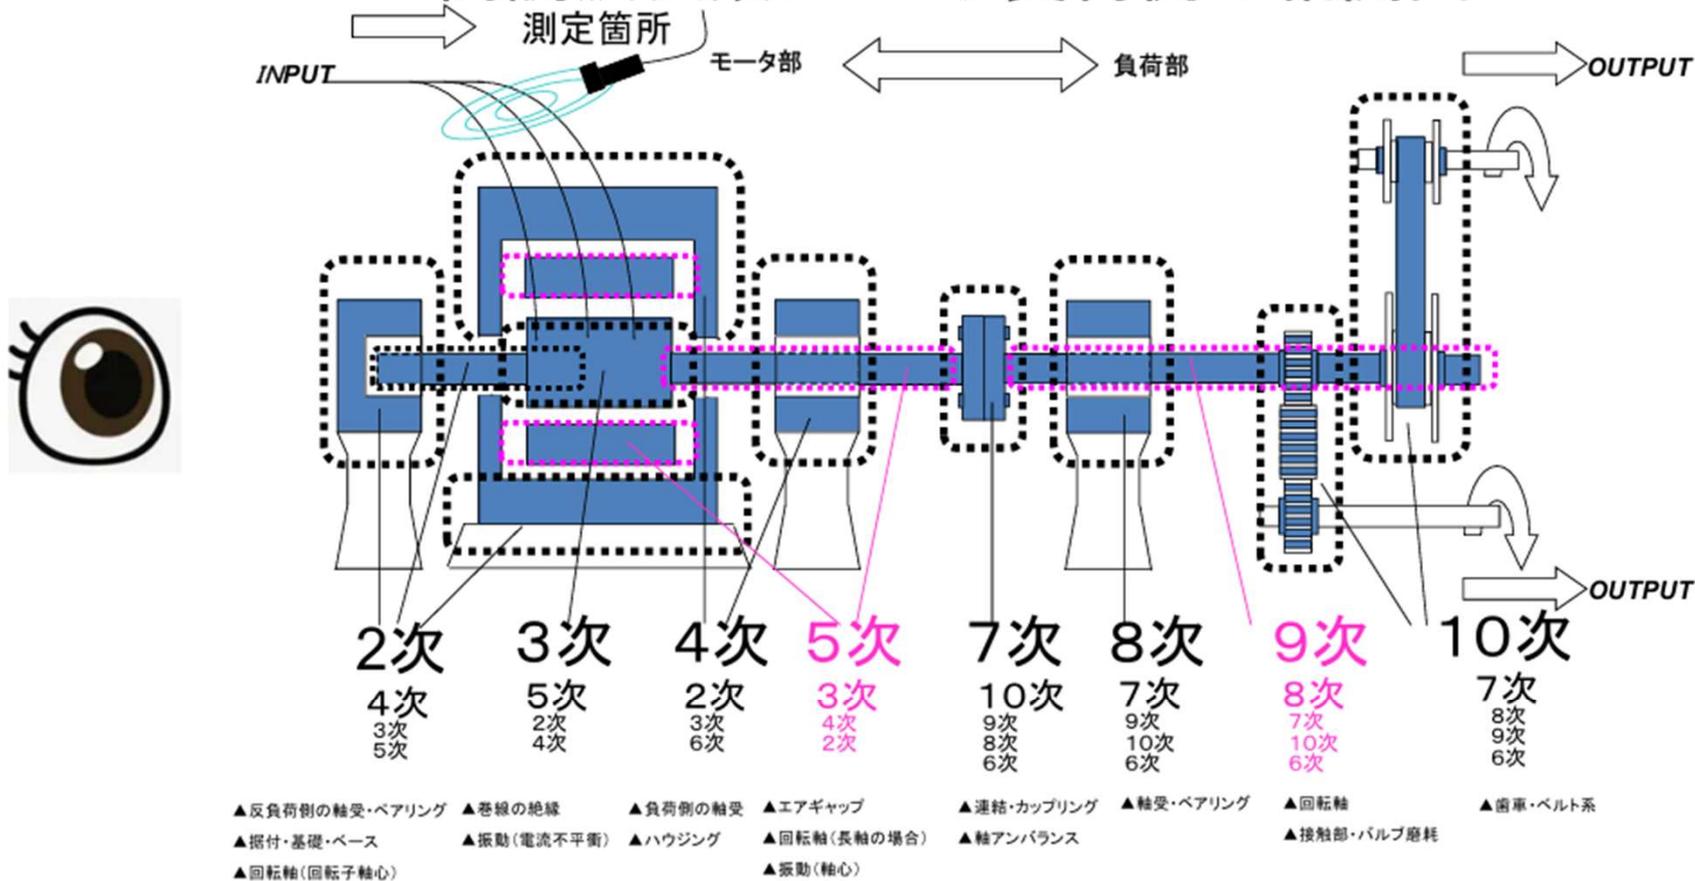
高調波診断システムにより得られる知見

- ◆ 高調波診断システムとは、高調波診断技術を用いた状態監視システムである。
- ◆ 設備の劣化箇所・劣化度合いと、高調波の立ち方に高い相関を見いだしたことによる、統計解析学の設備診断技術。
- ◆ 統計処理は、多変量解析の中の主成分分析法を用いている。
- ◆ 交流設備（インバータ含む）のみならず、直流設備（コンバータ含む）、トランス、コンデンサー、発電機、UPS（無停電電源装置）、送電ケーブルが測定可能である。

高調波診断技術の原理と特徴

- ◆ 設備の電源部での漏れ磁束をサーチコイルを用いて測定することで、電源電流波形に重畳される高調波を測定する。
- ◆ 非接触、活線であり、設備を停止する必要がない。
- ◆ 測定箇所は、制御盤の端子であり、水中ポンプや天井ファン等の診断も安全・容易である。
- ◆ 各高調波成分の含有率と高調波寄与率から劣化を示す管理数値が計算される。
- ◆ 管理数値の大小から裕度表により劣化度を求める。

高調波次数とモータ負荷側の相関図



アルカディア・システムズ株式会社

ストレス診断報告書

AC
R_1106-001_231107_235744.doc
2023/11/13

AC
R_1106-001_231107_235744.doc
2023/11/13

電気設備機器劣化診断結果報告書

■ 企業名 京都大学自治	■ 工場名 ヘリオトロンJ	
■ 診断日 23/11/07	使用測定器 KS-2000	
■ 稼働仕様	処理条件 既知、ヨロガリ、ヨコ型	
設備名 真空系純水送水ポンプ	設備コード 1106-001	
ライン名 -	設備分類 -	
インバータ -	定格容量 - kW	
製造会社	運転周波数 - Hz	
型式 -	型式 -	
モータ -	型式 -	
製造会社		
定格容量 - kW	定格電圧 - V	定格電流 - A
極数 - 極	周波数 - Hz	絶縁種 - 種

■ 高調波測定_{単位: %} ■ 電流測定

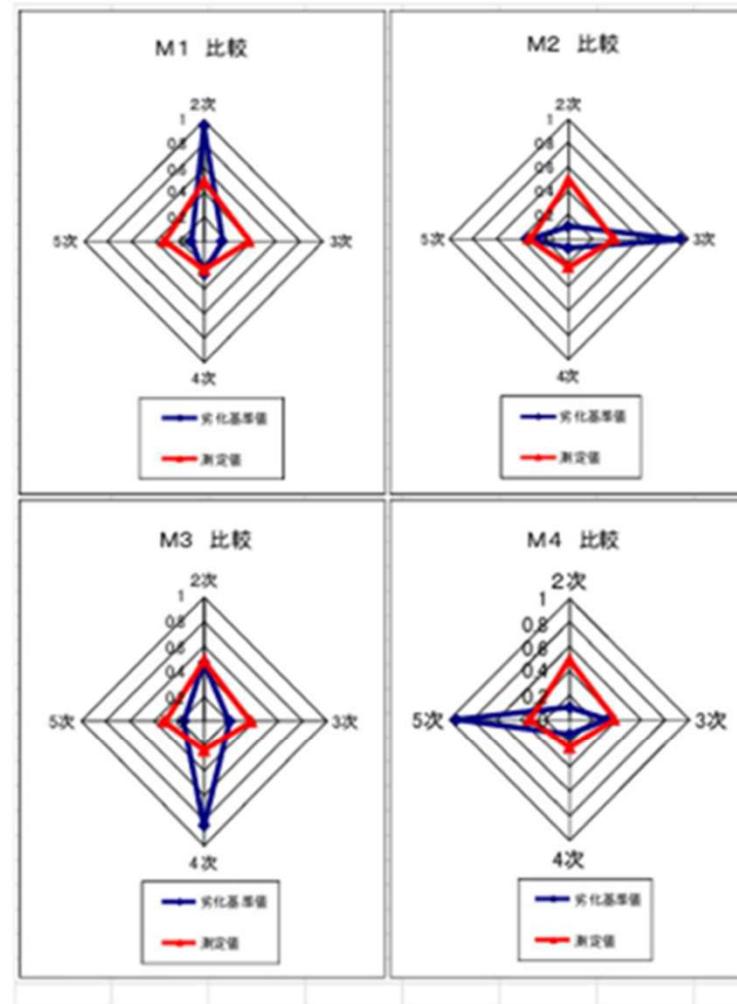
インバータ (二次側)	U相 - A	V相 - A	W相 - A
含有率	不平衡率 - %	電流測定結果	未測定

モータ (入力)、もしくはインバータ (二次側)

次数	2次	3次	4次	5次	6次	7次	8次	9次
含有率	2.7	2.1	1.3	1.8	0.5	0.5	0.5	0.6
10次	1.1次	1.3次	1.7次	1.9次	2.3次	2.5次	3.8次	総合
	0.4							5.5

■ 診断結果				コメント		
診断項目	【モータ部】		結果	劣化度	数値	正常運転 M1の劣化、軽度ストレス発現 M2の劣化、軽度ストレス発現 M3の劣化、軽度ストレス発現
	M1: 回転軸・軸受、潤滑付	B 1	41%	0.36		
	M2: 巻線の絶縁 (閉閉/閉閉) 劣化	B 1	40%	0.35		
	M3: 軸受・ハウジングの損傷	B 1	43%	0.200		
	M4: エアギャップ不均一・変動	A	39%	0.312		
	【負荷側】		結果	劣化度	数値	運転モード: 二次側固定 L1の劣化、軽度ストレス発現 L2の劣化、中程度ストレスレベル L3の劣化、中程度ストレスレベル L4の劣化、軽度ストレス発現 3ヶ月毎の傾向管理が実施されています
	L1: カップリング異常、軸の歪み	B 1	42%	0.078		
	L2: 軸受損傷、異物付着	B 2	60%	0.0806		
	L3: 回転軸異常、ノイズ発生	B 2	62%	0.0843		
	L4: 歯車・ベルト系損傷	B 1	49%	0.0763		
	【インバータ】		結果	劣化度	数値	
	I1: 平滑 (電容) コンデンサ	-	-	-		
	I2: コントロール基板	-	-	-		
	I3: 電力素子	-	-	-		
I4: ドライブ基板	-	-	-			

M1=0.36
M2=0.35



診断結果

- ◆ 純水循環ポンプ、純水送水ポンプ等、計7台の電気設備に関して高調波診断を複数回実施した。
- ◆ 純水送水ポンプ以外は概ね初期劣化状態であった。
- ◆ 純水送水ポンプ
 - ▶ 反負荷側回転軸が、劣化度(80%)以上であり、軸受けにグリス注入が必要な状態。
 - ▶ 改善が見られない場合、軸受け交換も必要。
- ◆ 今後、生成AIを導入したアナログ波形そのもの又はFFT波形そのものの利用が考えられる。

高調波診断の結果の動的信頼度評価 GO-FLOW解析への反映方法の検討

- ◆ 実際に機器を修理・新品へ取り換えなくても、劣化状態の情報が得られ、GO-FLOW解析へ反映でき、より高度・現実的な評価が可能となる。
 - 従来: 保守を実施しない限り解析条件は変更していない。
 - ➡ 劣化度を解析に組み入れる。
 - パラメトリックな考え方 $\lambda_{\delta} = (1-\alpha)\lambda_0 + \alpha\lambda_L$ α : 劣化度に応じた割合。
 - 経過時間付加方法: 故障率は変更せず、経過時間を劣化度に応じて付加し、故障確率を高く評価する。
 - 故障率一定の指数的な分布を変更する。例えばワイブル分布の様に寿命に限界がある様なモデルにする。
 - 劣化度を残存寿命に置き換え、それを故障率へ換算する。

高調波診断の結果の動的信頼度評価 GO-FLOW解析への反映方法検討(続き)

- ◆ 点検後の修理・交換の効果と併せた評価が可能となる。
- ◆ 現状の解析では修理後、機器は新品となるとの設定である。
- ◆ 修理後の機器の状態も劣化度の評価と同様な方法で評価し、必ずしも新品にならないとする方法を導入する。

AI技術の活用

－ Chat GPTによる劣化度、保守効果のモデルの探索 －

- ◆ 機器の点検後、修理を実施した後は機器は新品になるというモデルのもと解析を実施してきた。
- ◆ 機器の修理の結果、機器がある程度良好な状態になることも考えられるが、どの様なモデルが存在するかの調査を依頼。
- ◆ 得られたモデルを用いたアベイラビリティ解析を再度実施する。
- ◆ 高調波診断の知見(劣化度)を反映した解析も組み入れる。

◆ Chat GPT に問い合わせた結果以下の情報が得られた。

◆ 機器の修理の結果の効果のモデル各種

- パラメトリックな考え方 $\lambda_s = (1-\beta)\lambda_0 + \beta\lambda_L$ β : 修理に応じた割合。
- 経過時間調整方法：故障率は変更せず、経過時間を修理に応じて付加し、故障確率を高く評価する。
- 故障率一定の指数的な分布を変更する。
- 修理の程度に応じて残存寿命を設定、それを故障率へ換算する。

➤ 各種モデルの整理を依頼した結果以下の情報が得られた

○

- **提案**：Brown & Proschan (1983) による論文。
- **目的**：修理後に「新品同様 (AGAN)」になるか「古いまま (ABAO)」になるかを単純にモデル化する。
- **発想**：現実の修理では「完全修理 (renewal)」と「最悪の修理 (minimal repair)」の中間が起きるが、それを確率的に切り替える。
- 機器が故障したとき、修理が行われる。
- 修理後の状態は次の2通りのどちらかになる：
 - 完全修理 (renewal)：機器は新品同様になる（寿命分布がリセット）。確率 p 。
 - 最小修理 (minimal repair)：修理後も「故障発生直前と同じ年齢」を保つ。つまり劣化はそのまま。確率 $1-p$ 。
- 各故障ごとに、修理のタイプは独立に確率的に決まる。
- 修理の質を確率 p という一つのパラメータで表せる。
 - $p=1$ → (リニューアル過程)
 - $p=0$ → 故障間隔は「条件付き寿命分布」に従い、非ホモジニアス・ポアソン過程 (NHPP) になる。
 - $0 < p < 1$ → 不完全修理
- 発電設備、原子力機器、航空機エンジンなど、修理で新品同様にできないシステムの信頼性解析に使える。Brown-Proschan モデルは「修理後の状態が確率的に新品同様か古いままかを定めるシンプルな不完全修理モデル」で、信頼性解析や可用性評価にとってもよく使われる。

◆ Kijima モデルの概要

- Brown-Proshchan モデルをさらに一般化したものが Kijima モデル (Kijima's Generalized Renewal Process, GRP) です。これは「修理後ほどの程度“若返る”か」を連続的に表現できるため、信頼性工学や保全工学で非常によく使われています。
- Kijima モデルの基本的考え方：修理後の機器は「完全に新品」でも「まったく古いまま」でもなく、その中間の状態になることが多い。そこで、**修理の効果を劣化度 (virtual age, 仮想年齢)** という概念で表現する。故障時刻ごとに「仮想年齢」が更新されていく。
- **仮想年齢 (Virtual Age)**：機器の「実際の経過時間」ではなく、寿命分布に対して有効な年齢を使って表現する。修理の効果は、この「仮想年齢」をどれだけリセットするかに反映される。
- Kijima モデルの定義：機器が故障した時点までの稼働時間を X_i 、修理後の仮想年齢を V_i とすると：
 - **モデル I (加法型モデル)**
 $V_n = V_{n-1} + q_n X_n$, X_n : n 回目の稼働時間 (故障間隔) q_n : 修理効果係数 ($0 \leq q_n \leq 1$)
 - **特徴：**
 $q_n = 0$ → 完全修理 (新品同様, AGAN) $q_n = 1$ → 最小修理 (ABAO, 累積時間そのまま)
 $0 < q_n < 1$ → 部分的な若返り (不完全修理)

◆ Kijima モデルの概要(2)

- **モデル II (乗法型モデル)** : $V_n = qnV_{n-1} + Xn$ 修理によって「過去の劣化」が縮小される形。
- **特徴** : $qn=0$ → 完全修理 (新品同様, AGAN) $qn=1$ → 最小修理 (古いまま) $0 < qn < 1$ → 過去の劣化を一部リセット

- まず、寿命時間 T を持つ機器の 分布関数 : $F(t) = P(T \leq t)$

信頼度関数 : $R(t) = 1 - F(t)$

故障率 (ハザード関数) : $\lambda(t) = \frac{f(t)}{R(t)} = \frac{f(t)}{1 - F(t)}$ で表されます。

ここでの $\lambda(t)$ は「時刻 t の年齢の機器が、次の瞬間に故障する確率」。

- 例えば、ワイブル分布の寿命を持つ機器を考えます。

➤ 信頼度関数 : $R(t) = \exp\left(-\left(\frac{t}{\eta}\right)^\beta\right)$

➤ 故障率 : $\lambda(t) = \frac{\beta}{\eta} \left(\frac{t}{\eta}\right)^{\beta-1}$

◆ Kijima モデルの概要(3)

ケース比較 修理前に5年使用した機器 ($\eta=10, \beta=3$ と仮定)

故障率： $\lambda(5)=3/10(5/10)^2=0.075$

➤ 完全修理 ($q=0$) 修理後の仮想年齢 $V=0$

故障率： $\lambda(0)=0$ (新品なので即故障はない)

➤ 最小修理 ($q=1$) 修理後の仮想年齢 $V=5$ 故障率： $\lambda(5)=0.075$

➤ 不完全修理 ($q=0.6$) 修理後の仮想年齢 $V=0.6 \times 5=3$

故障率： $\lambda(3)=3/10(3/10)^2=0.027$

➤ このように、仮想年齢を修理ごとに更新して、その値を使ってハザード関数を計算するという意味

➤ イメージまとめ

「新品に戻す」 → 仮想年齢 0

「まったく戻さない」 → 仮想年齢 = 実年齢

「部分的に若返り」 → 仮想年齢 = 実年齢の一部 (q 倍など)

→ その仮想年齢を使って次の故障率を計算していく。

◆ Kijima モデルの概要(4)

➤ 修理前の信頼度

例えば、機器を5年間運転した状態で考えます。

既に5年経過しているので、「残り寿命の分布」を考える必要があります。

このときの条件付き信頼度は次のように表されます：

➤ $R(t|すでに5年生存)=R(5)/R(5+t)$

これは「すでに5年持った」という条件で、さらにあと t 年持つ確率です。

➤ 修理後の信頼度 (不完全修理, $q=0.6$ の場合)

修理の効果を「仮想年齢」によって表します $\frac{f(t)}{R(t)} = \frac{f(t)}{1 - F(t)}$

➤ 修理前の年齢：5年

修理後の仮想年齢： $V=q \cdot 5=0.6 \times 5=3$ 年

つまり「修理後の機器は新品ではないが、3年使った状態の機器と同等」とみなします。

➤ このとき修理直後からの信頼度は： $R(t|仮想年齢 V)=R(V)/R(V+t)$

ここで $V=3$ を代入します。

◆「分布を変更する」モデル

1. リニューアル理論 (Renewal Theory) に基づくモデル

- ▶ 定期交換や完全修理 (AGAN) をすると、寿命分布 $F(t)$ がリセットされます。例えば「 n 時間ごとにオーバーホールする」と仮定すれば、寿命分布そのものを定期的にリニューアルする形になります。この場合、システム全体の信頼度関数は「繰り返し分布」を畳み込んだ形で表されます。

2. 不完全更新モデル (Imperfect Renewal Models)

- ▶ 修理や保守後に、寿命分布のパラメータを変化させる形で表現する方法。

代表例：ワイブル分布のパラメータ変更

Scale パラメータ更新モデル (例えばワイブル分布の η を修理ごとに増やす/減らす)

Shape パラメータ更新モデル (疲労が進むと形状パラメータ β が変わる)

- ▶ これにより「修理を重ねると次第に壊れやすくなる」「部品交換で逆に寿命が延びる」といった効果を直接分布に反映できます。

◆「分布を変更する」モデル(2)

3. 混合分布モデル (Mixture Models)

- ▶ 修理後の機器は「新品同様」と「古いまま」の混合分布に従うと仮定する。これは Brown-Proschan を分布の観点から見直したものとと言えます。

例えば： $F_{\text{after repair}}(t) = p \cdot F(t) + (1-p) \cdot F(t + T_{\text{age}})$

ここで p は完全修理の確率、 T_{age} は修理前の実年齢。

4. 予防保全モデル (Preventive Maintenance Models)

- ▶ 保守により「寿命分布そのものを改善」するモデル。

完全予防保全：寿命分布を新品同様にリセット。

不完全予防保全：寿命分布のパラメータを部分的に戻す。

実務では「最適保全間隔の計算 (Age Replacement Policy)」に多用されます。

◆ パラメータ更新型の具体例

(a) パラメータ更新型

- ▶ ワイブル分布を例にすると：
$$F(t) = 1 - \exp \left[- \left(\frac{t}{\eta} \right)^\beta \right]$$
- ▶ 保守効果を「尺度母数 η の増加」として表現。
(例：小保守で $\eta \rightarrow 1.2\eta$ 、大保守で $\eta \rightarrow 2\eta$)
- ▶ 形状母数 β はそのまま (故障モードが変わらない前提)。

(b) バーチャルエイジ (Virtual Age) モデル

- ▶ 機器の「仮想的な使用時間 $v(t)$ 」を導入し、保守後は実年齢より若返った状態に戻す。
 - ▶ $F(t) = F_0(v(t))$
 - ・例: 完全保守 $\rightarrow v(t) = 0$ にリセット
 - 部分保守 $\rightarrow v(t) = \alpha t, 0 < \alpha < 1$
- この考え方は *Kijima*モデル (タイプI, II) として知られている。

◆ パラメータ更新型の具体例(2)

(c) ミックス分布型

- 保守後の状態を「新品確率 p 」「劣化状態継続確率 $1-p$ 」で表す混合分布。

$$F_{\text{after}}(t) = pF_{\text{new}}(t) + (1 - p)F_{\text{aged}}(t)$$

4. 実務上の活用

- 単純モデル: ワイブル分布のスケールパラメータを変更して寿命延長を表現。
- 高度モデル: バーチャルエイジやマルコフモデルで「部分的復元」や「保守失敗確率」を組み込む。
- 解析方法:
 - 平均残存寿命 (MRL: Mean Residual Life) を更新する形で解析。
 - または保守時点で分布を条件付き分布にリセット。

アベイラビリティ解析の高度化

(a) 高調波診断の知見の反映

- ◆ 劣化度→残存寿命推定→指数分布故障にて故障率推定。
- ◆ 経過時間 t_1 の時、残存寿命 t_L と推定されたとする。
- ◆ $t_1 + t_L$ における故障確率が99%となる故障率 λ_L を算出。
- ◆ その機器の故障率を λ_L に置き換えてGO-FLOW解析を再実施、評価する。
- ◆ 高調波診断の知見を反映し、修理する前の状態におけるアベイラビリティが評価できる。

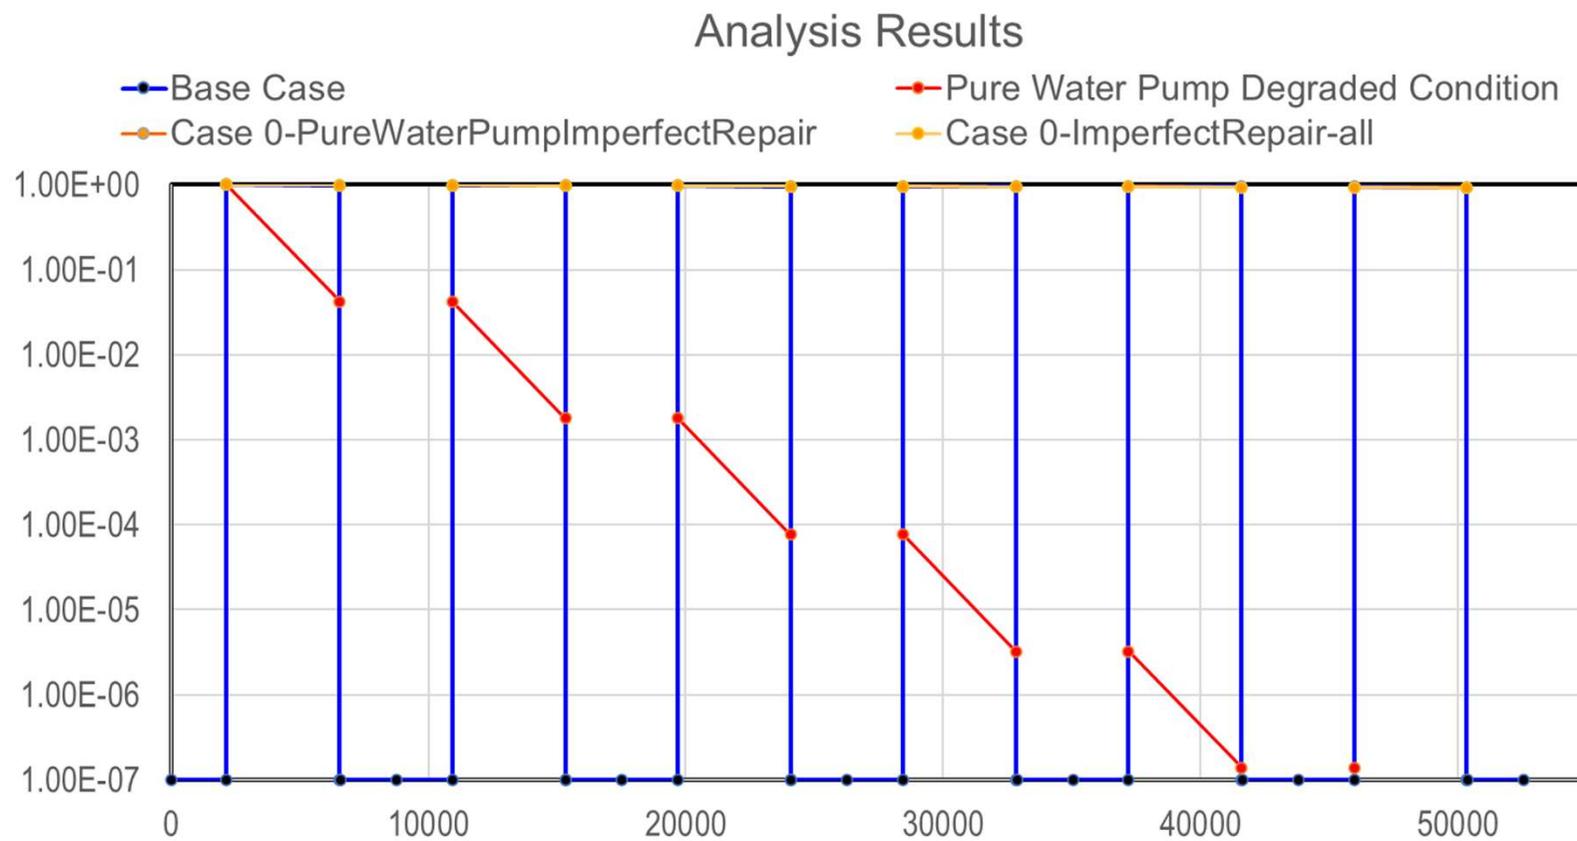
◆ 具体的な推定例

(例)純水送水ポンプ劣化度80% それ以外は初期劣化状態。

- ▶ 元々故障率 $\lambda = 1.0 \times 10^{-6} / \text{h}$ と設定。前回から半年の運転経過時 (728 h) に高調波診断を実施。
- ▶ 劣化度80%と評価される。
- ▶ 劣化度80%とは “1日8時間稼働で1ヶ月から3ヶ月以内での適切な対応を奨励”
- ▶ 今後3か月稼働時に故障確率0.99とする。4週 x 28時間 x 3か月 = 336h
- ▶ 残存時間3か月 (336 h) $728 + 336 = 1064 \text{ h}$ で寿命が尽きる (99%故障確率) とする。
- ▶ $\lambda_L = 4.3282 \times 10^{-3} / \text{h}$ となる。
*) $\lambda_L = \text{Log}_{10}(0.01) / 1064 \times \log_{10}(e)$

解析結果－高調波診断結果を反映

- 実験開始直前に診断実施して知見を得た場合。



アベイラビリティ解析の高度化

(b) 保守効果の組み込み

- ◆ 高調波診断実施時 (t_1) 以降時刻 t_m において保守を実施した場合の取り扱い。
 - 故障率を λ_L から λ に戻す。
 - 保守の効果 α を考慮して t_m までの経過時間を αt_m と設定して評価する。
 - 解析結果は時刻 t_m 以降のみ有効。

(b) 保守効果の組み込み (2)

- ◆ 経過時間を α 倍に変更する。 $0 \leq \alpha \leq 1$ となる
- ◆ 前回の修理時間からの経過時間 $(t_2 - t_1)$
保守効果 α : 経過時間 $\alpha \times (t_2 - t_1)$ を t_1 の経過時間
に加算する。
- ◆ $\alpha = 0$: 完全保守
- ◆ $0 < \alpha < 1$: 部分保守
- ◆ $\alpha = 1$: 保守効果ゼロ
- ◆ $1 < \alpha$: 保守作業実施により状態悪化。

……保守ミス、ヒューマンエラー等。

◆ 解析への適用例

(例)純水送水ポンプ劣化度80% それ以外は初期劣化状態。

ケース1：

- ▶ 元々故障率 $\lambda = 1.0 \times 10^{-6}/h$ と設定。前回から半年の運転経過時 (728 h) に高調波診断を実施。
- ▶ 劣化度80%と評価される。
- ▶ 劣化した純水送水ポンプの保守を実施、 $\alpha = 0.3$ と設定。
(前回修理後の運転時間の0.7倍の値をマイナス値 (-510h)として入力する。)
- ▶ 他の機器については $\alpha = 1.0$ の保守を実施。

ケース2：

- ▶ 全ての機器について、不完全保守を実施。 $\alpha = 0.3$ と設定。

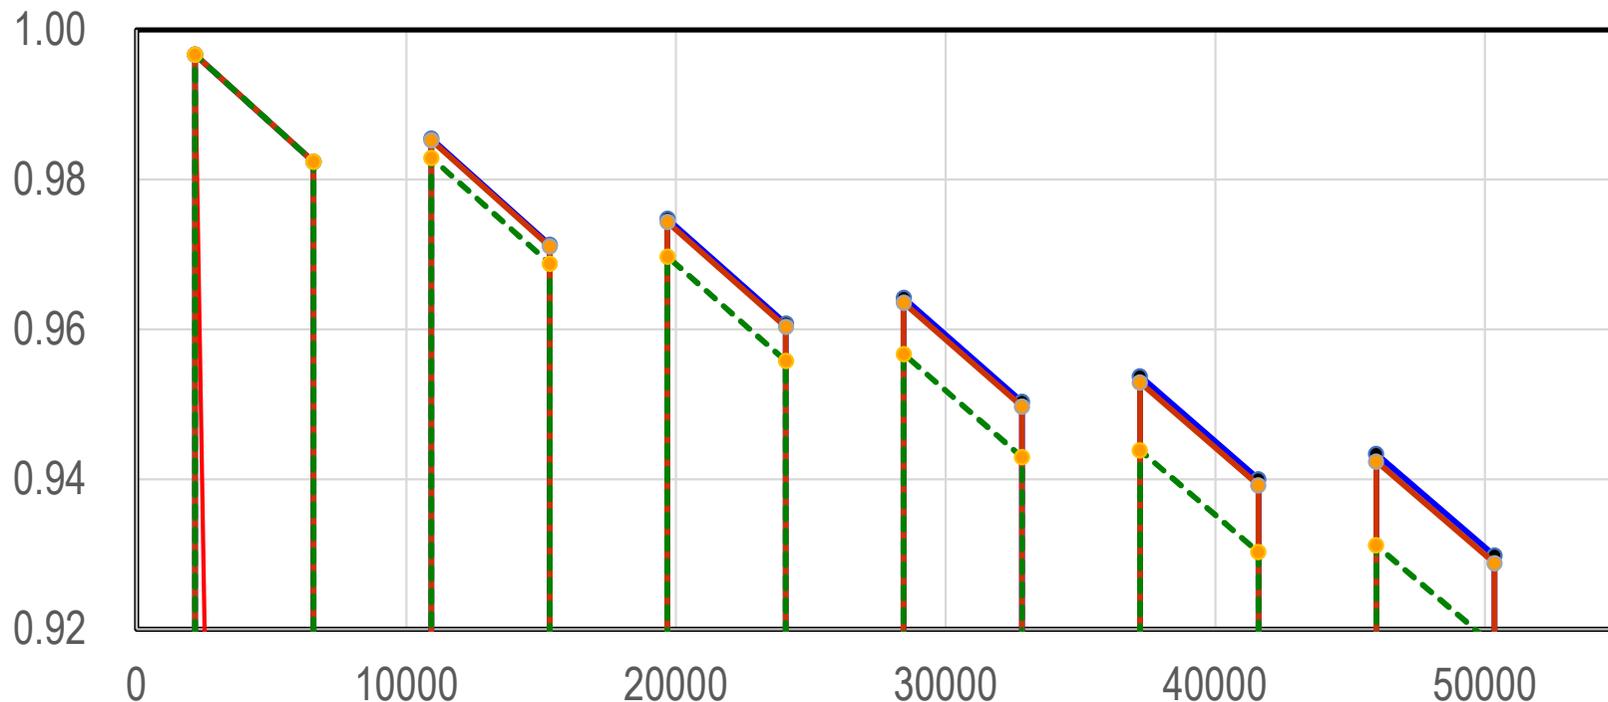
解析結果

一高調波診断結果と不完全保守効果を反映

➤ ケース1 と ケース2

Analysis Results

● Base Case



◆ 解析への適用例

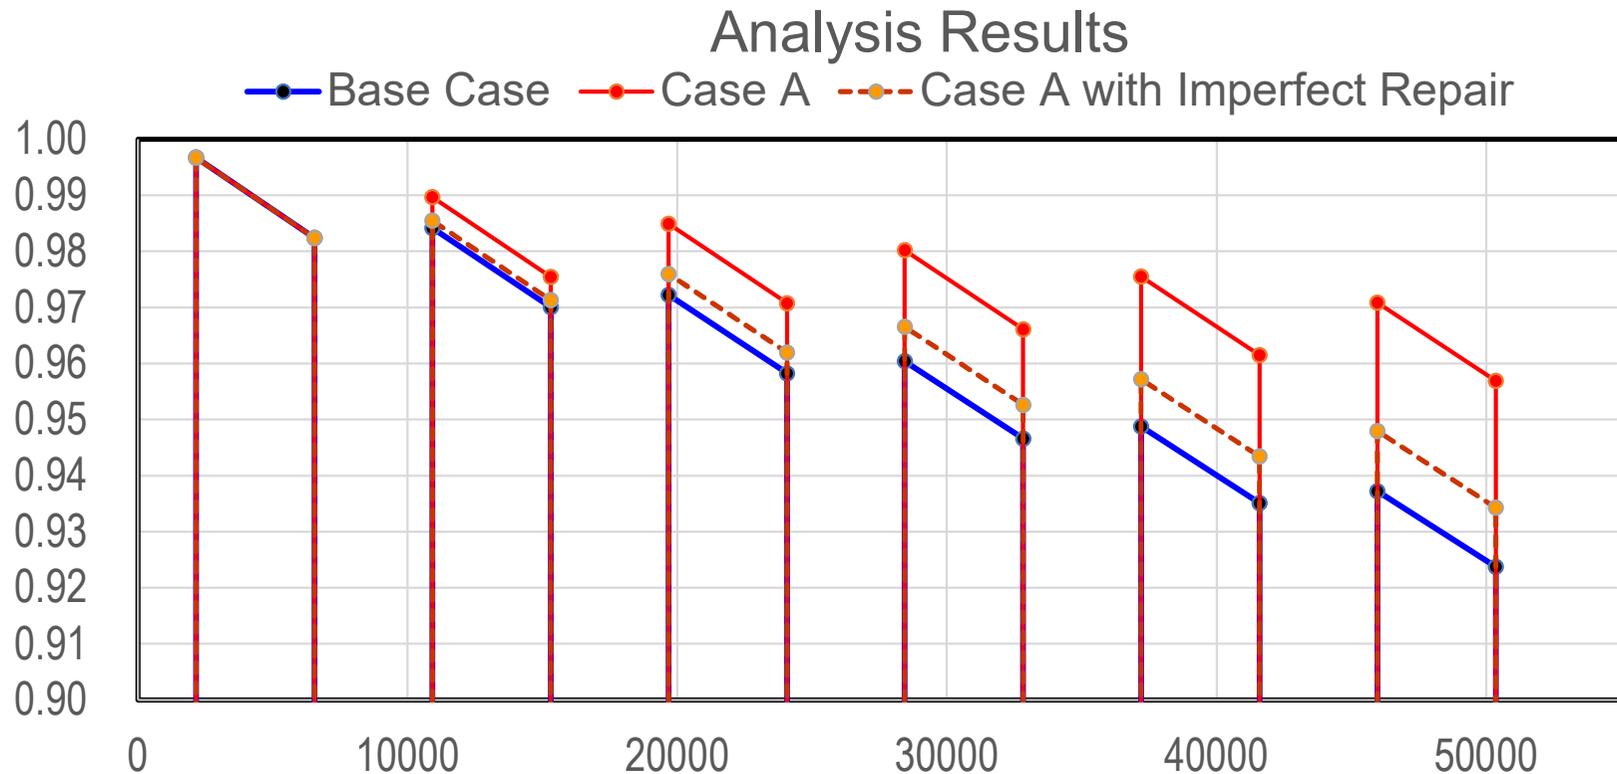
ケース3：

- ▶ *CaseA* において、すべての機器に対して不完全保守 $\alpha = 0.3$ を実施。
- ▶ *Base Case*, *Case A* の完全保守（機器状態が新品同様に戻る）と比較。

解析結果

一高調波診断結果と不完全保守効果を反映

➤ ケース3



Chat GPT の有用性

- ◆ ChatGPTはGO-FLOWをどの程度理解しているか。
 - ➔ 情報はかなり正確に把握している。
- ◆ 信頼性解析・アベイラビリティ解析は補助情報を与えると比較的正確に実施する。
- ◆ 信頼性ブロックダイアグラムのなものは作成できる。
- ◆ GO-FLOWチャートの様な概念図の作成は無理であった。
- ◆ 保守・修理の効果についての既存モデルの情報収集、整理は効率的に行える。
 - ➔ 有用な情報収集、整理には便利である。

高調波診断結果の活用／保守効果の アベイラビリティ解析への組み込み

高調波診断結果

- ◆ 劣化度→残存寿命推定→指数分布の故障故障率の変更として扱う方法で解析へ反映。

保守効果の考慮

- ◆ 経過時間を α 倍に変更する方法により解析へ反映。

今後のアベイラビリティ解析高度化の方針

- ◆ 劣化度を解析に組み入れる。
 - 劣化度を残存寿命に置き換え、それを故障率へ換算する。
- ◆ 保守の結果、改善する程度を解析に反映させる。
 - 経過時間調整方法：故障率は変更せず、経過時間を修理に応じて付加し、故障確率を高く評価する。
- ◆ 現場に即した解析の実施
 - 今回の予備解析結果をヘリオトロン運用担当者に説明して解析条件の妥当性をチェックする。
 - 保守の効果を現場ではどう捉えているか、実態の情報収集を行う。
 - 合理的・妥当な保守計画の複数候補を運用者ととともに策定。
 - 上記条件での解析結果の評価をおこなう。
 - 現場の実態に即した保守・管理計画の策定方法の確立を目指す。