

## ウェットエッチングプロセスにおける少サンプル下での レシピ作成および検証を行う AI システム AI System for Recipe Creation & Verification of Single Wafer Wet Etching in Scarce Data Conditions

東大工<sup>1</sup>, SCREEN SPE<sup>2</sup> ◯(M1)柴田 行輝<sup>1</sup>, 堀口 博司<sup>2</sup>, 松井 千尋<sup>1</sup>, 竹内 健<sup>1</sup>,  
Univ. Tokyo<sup>1</sup>, SCREEN SPE<sup>2</sup>, ◯Koki Shibata<sup>1</sup>, Hiroshi Horiguchi<sup>2</sup>, Chihiro Matsui<sup>1</sup>, Ken Takeuchi<sup>1</sup>  
E-mail: koki.shibata@co-design.t.u-tokyo.ac.jp

枚葉処理のウェットエッチングプロセスにおいては、高速で回転するウエハ表面にノズルが薬液を滴下することによりウエハ表面の化学反応を通して洗浄が行われる。半導体微細化に伴い、歩留まり向上のためエッチングレートの均一性への要求は高まりつつあるが、これまでプロセスエンジニアの経験に依存して、ノズル動作やウエハ回転速度など複雑なプロセスレシピの決定がなされてきた。本研究においては、レシピ作成の自動化を行う Backcasting AI と推定されたレシピの検証を行う Forecasting AI の2つの AI モデルを提案し、ウェットエッチングプロセス全体を仮想空間でシミュレーションすることを提案する(Fig. 1) [1]。

提案された Backcasting AI は2層のニューラルネットワークを複数訓練しアンサンブルすることで過学習を防ぎつつ少サンプル下でのモデルの訓練を効率化する(Fig. 2)。ノズルの周期的な動きを周期などの情報を含む8次元ベクトルで表現し、これを目的変数とする。説明変数としては、エッチング結果だけでなく、区間差分や区間分散といった特徴量エンジニアリングを行い更なるネットワークの学習の効率化を図る。説明変数作成時に使用される区間差分の幅といったハイパーパラメータはグリッドサーチにより最適化される。この結果、RMSE(Root Mean Squared Error, 二乗平均平方根誤差)は特徴量導入前より0.029改善し、アンサンブルを導入することにより0.021さらに改善される。Forecasting AI においては、ノズルの半径位置ごとの累積滞在時間をモデルの入力として、エッチング結果の予測を行う(Fig. 3)。その際、説明変数においてクリッピング処理を施すことで、従来モデル[2]において外れ値がモデルの学習を阻害する問題点を改善する。RMSEとMEP(Mean Error Percentage, 平均誤差率)をそれぞれ先行モデルと比較して0.0022、0.57だけ改善し、実測値との誤差を縮めることに成功した。

謝辞 本研究に際し、ご協力くださった SCREEN 三河氏、高橋氏、太田氏、吉永氏に御礼申し上げます。

参考文献 [1] K. Shibata et al., *SNW*, pp. 117-118, 2024. [2] S. Yoshikiyo et al., *SNW*, pp. 2-3, 2023.

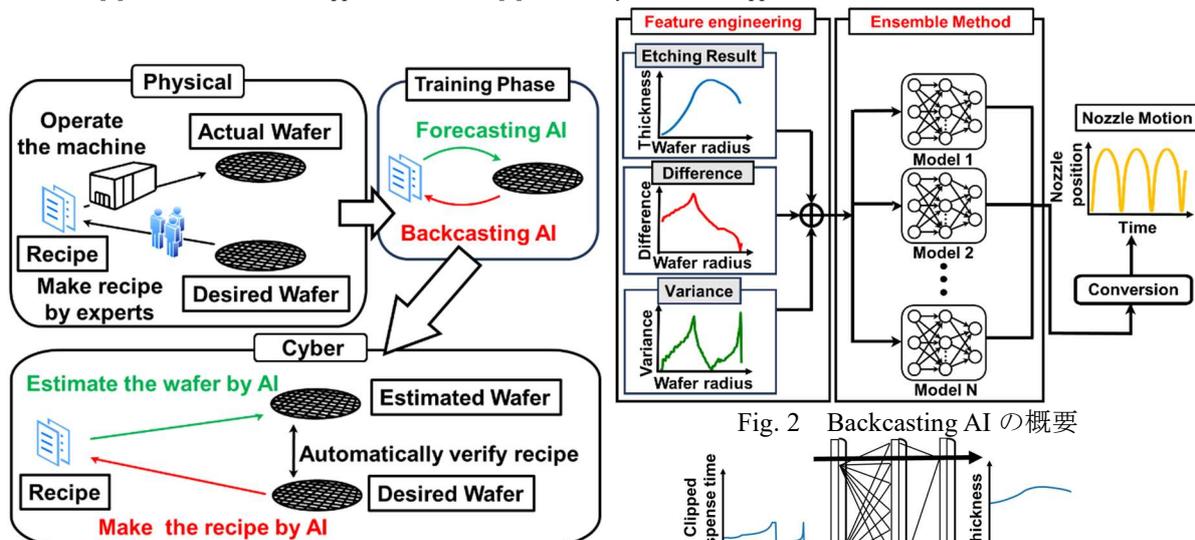


Fig. 1 ウェットエッチングプロセスにおける Backcasting AI と Forecasting AI

Fig. 2 Backcasting AI の概要

Fig. 3 Forecasting AI の概要