
Multi-Periodicity and Multi-Scale Approaches For Time Series Analysis

DMQA Open Seminar

2025.02.21

Data Mining & Quality Analytics Lab.

정구진

발표자 소개



정구진

- 고려대학교 산업경영공학과 대학원 재학
- Data Mining & Quality Analytics Lab. (김성범 교수님)
- Ph.D. Student (2023.03 ~ Present)

Research Interest

- Multivariate Time Series Modeling
- Generative models

Contact

- kujhin@korea.ac.kr
-

TABLE OF CONTENTS

01

- Background
 - Time Series
 - Decomposition
 - FFT

02

- TimesNet
 - Overview
 - 방법론

03

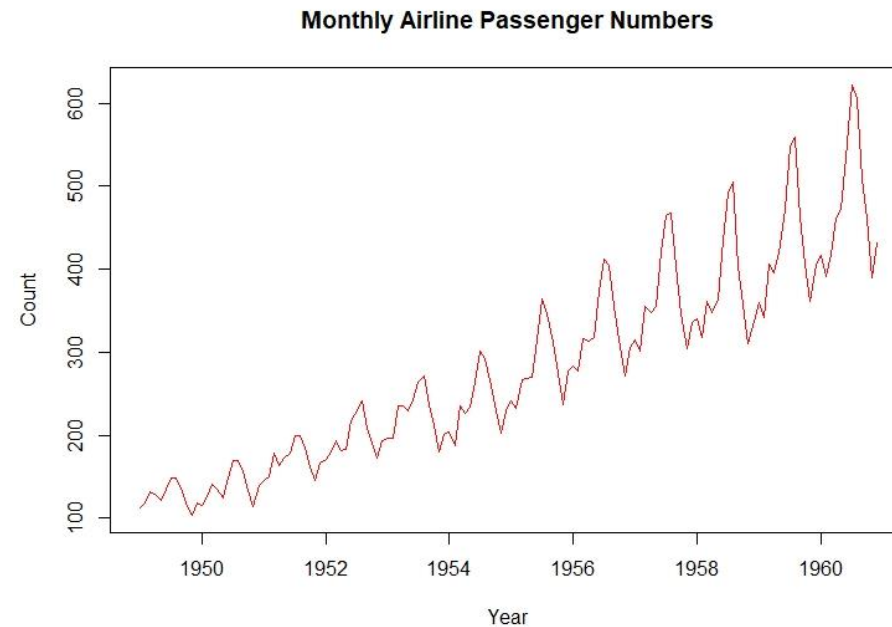
- TimeMixer
 - Overview
 - 방법론



01 Time Series 개념

Time Series Data


- 시계열 데이터는 특정 시간 순서에 따라 연속적으로 측정된 데이터 포인트의 집합
- 데이터 포인트들이 시간에 따라 순차적으로 연결되어 있으며, 이전 관측값이 현재 및 미래 관측값에 영향을 미침



01 Time Series 개념


Time Series Analysis

Forecasting




과거 데이터 패턴을 기반으로 미래의 값을 추정

Classification




시계열 데이터를 미리 정의된 여러 클래스나 범주로 분류하는 기법

Anomaly detection



정상적인 패턴에서 크게 벗어난 데이터 포인트를 식별하는 기법

Imputation



시계열 데이터에서 누락된 값을 추정하여 채우는 기법

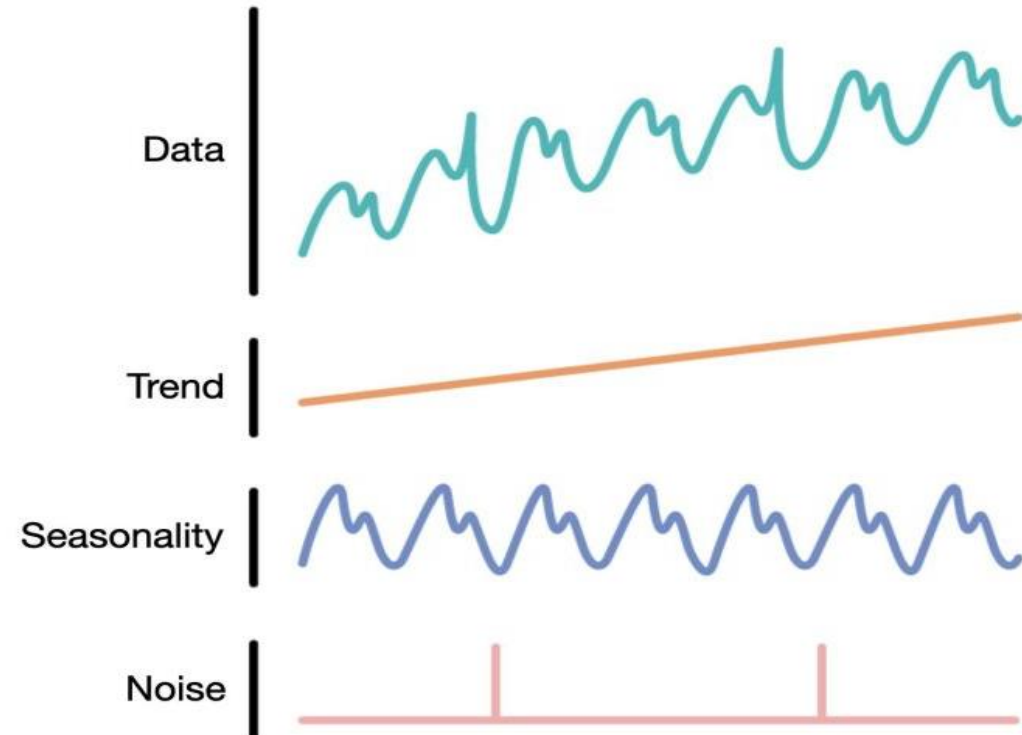
01 Decomposition

Time Series Decomposition

- 복잡한 시계열을 predictable한 구성 요소로 나누어 분석할 수 있음
- 1919년 Warren Persons가 처음으로 trend, seasonal, cyclical, irregular 요소로 분해하는 법 제안

Component of Time Series

- Trend (추세)
 - 데이터의 장기적인 방향성
 - 시간이 지남에 따라 증가하거나 감소하는 패턴
- Seasonality (계절성)
 - 일정한 주기로 반복되는 패턴 (아이스크림, 전력 소비)
- Noise (불규칙 변동)
 - 예측할 수 없는 무작위적 변동



https://www.linkedin.com/posts/julius-ai_what-is-time-series-decomposition-and-activity-7121268026921910272-Wrfb/

01 Decomposition





딥러닝에서 Decomposition 적용하는 방법

- N-Beats(2019)는 딥러닝 모델에서 decomposition을 명시적으로 수행한 초기 사례
- Autoformer(2021)는 신경망에서 분해하는 N-Beats의 방식과 다르게 통계적 방법을 활용하여 입력을 먼저 분해하고 이들을 병렬로 처리하였으며, 최근에는 많은 방법론에서 기본적으로 사용
(예시: kernel size 2, stride 1, padding 1)


Padding




AvgPool



-



=






01 FFT(Fast Fourier Transform)

Fourier Series

- 같은 형태를 반복하는 주기를 가진 파동은 단순한 파동의 결합으로 이루어질 수 있음
- 임의의 주기 함수 $f(t)$ 가 있을 때, 이는 상수 a_0 와 다양한 주기를 가지는 \cos/\sin 함수들의 합으로 표기할 수 있음

$$f(t) = a_0 + a_1 \cos \omega t + a_2 \cos 2\omega t + \dots + a_n \cos n\omega t + b_1 \sin \omega t + b_2 \sin 2\omega t + \dots + b_n \sin n\omega t$$



종료

Handling Signal Data with Fourier Transform
DMQA Open Seminar

Changhyun Kim
Department of Industrial and Management Engineering
Korea University
June 10, 2022

Handling Signal Data with Fourier Transf

발표자: 김창현

📅 2022년 6월 10일
🕒 오후 1시 ~
▶ 온라인 비디오 시청 (YouTube)

세미나 정보 보기 →


<https://youtu.be/q7U1LX2BdOA?si=d6CJfzu7hSwKYDu>
<https://www.nti-audio.com/en/support/know-how/fast-fourier-transform-fft>



Background

01 FFT(Fast Fourier Transform)

Fourier Transform

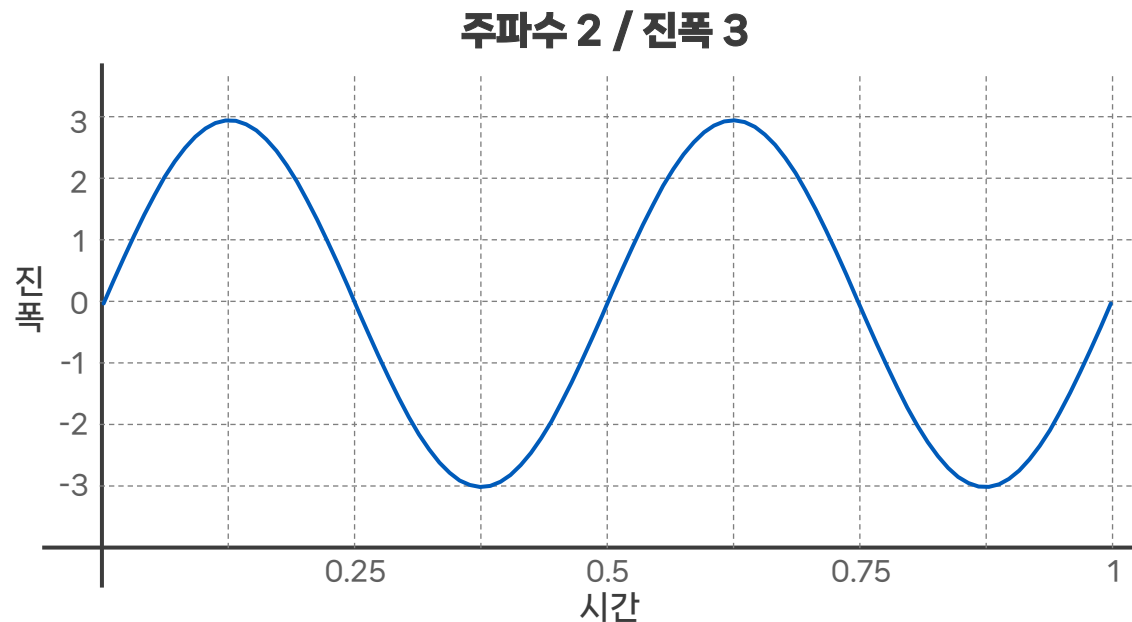




Background

01 FFT(Fast Fourier Transform)

Fourier Transform







Background

01 FFT(Fast Fourier Transform)

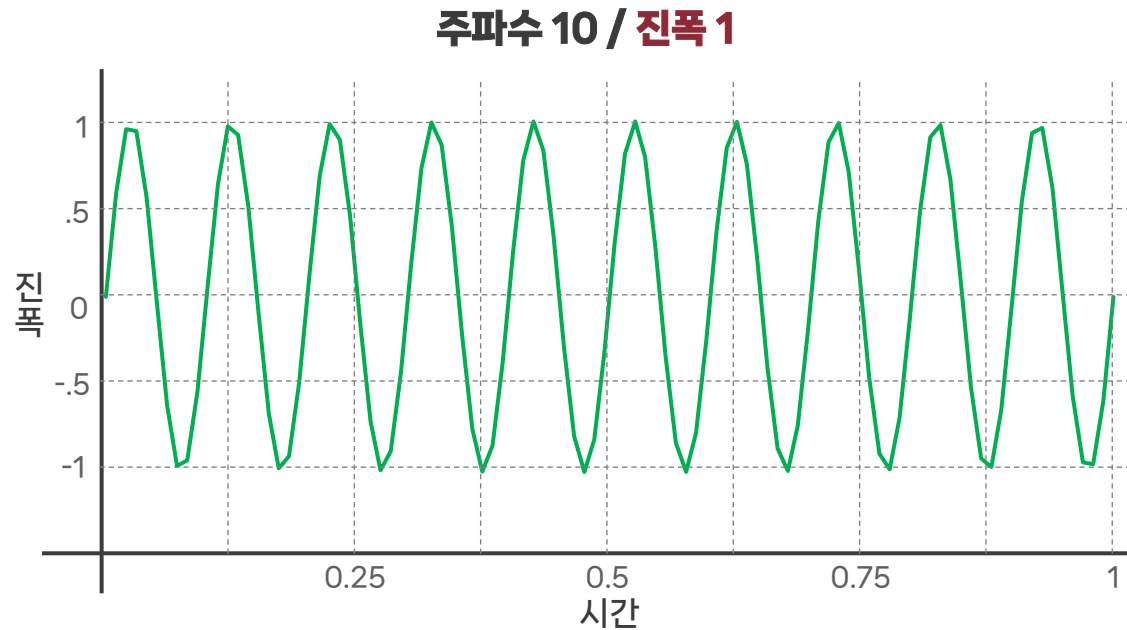


Fourier Transform





01 FFT(Fast Fourier Transform)




Fourier Transform






01 FFT(Fast Fourier Transform)

Fourier Transform






모든 성분을 합치면?






01 FFT(Fast Fourier Transform)

Fourier Transform



모든 성분이 합쳐진 신호






Background

01 FFT(Fast Fourier Transform)

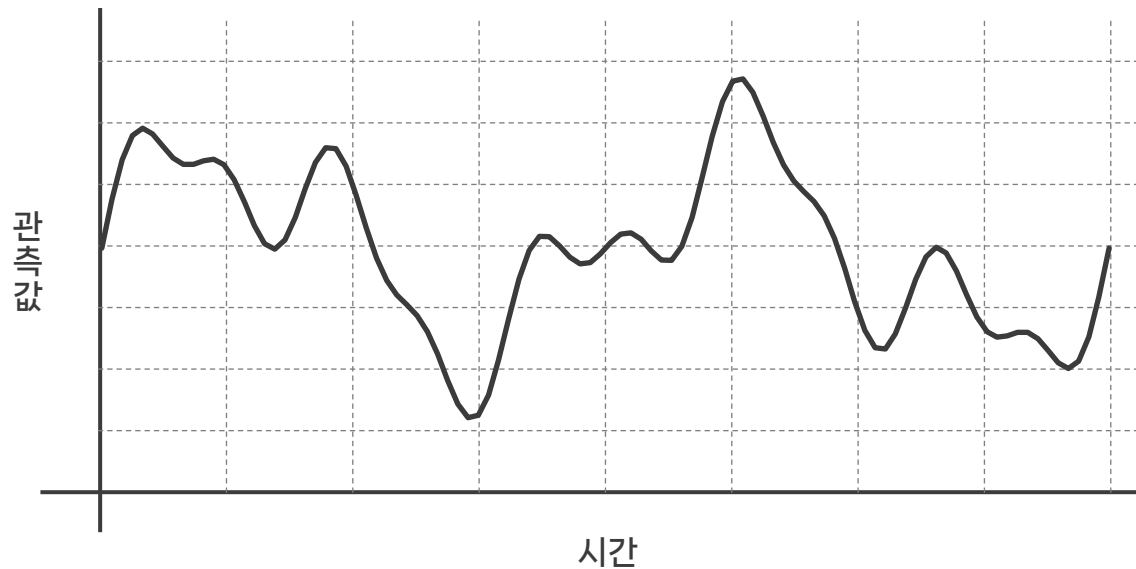
Fourier Transform





01 FFT(Fast Fourier Transform)

Fourier Transform



$$f(t) = a_0 + a_1 \cos \omega t + a_2 \cos 2\omega t + \dots + a_n \cos n\omega t + b_1 \sin \omega t + b_2 \sin 2\omega t + \dots + b_n \sin n\omega t$$

$$f(t) = a_0 + \sum_{n=1}^{\infty} [a_n \cos(n\omega t) + b_n \sin(n\omega t)]$$

- a_0 : 함수의 평균값
- a_n/b_n : cos / sin 항의 계수
- $\omega = \frac{2\pi}{T}$: 기본 각 주파수이며, T는 주기



01 FFT(Fast Fourier Transform)

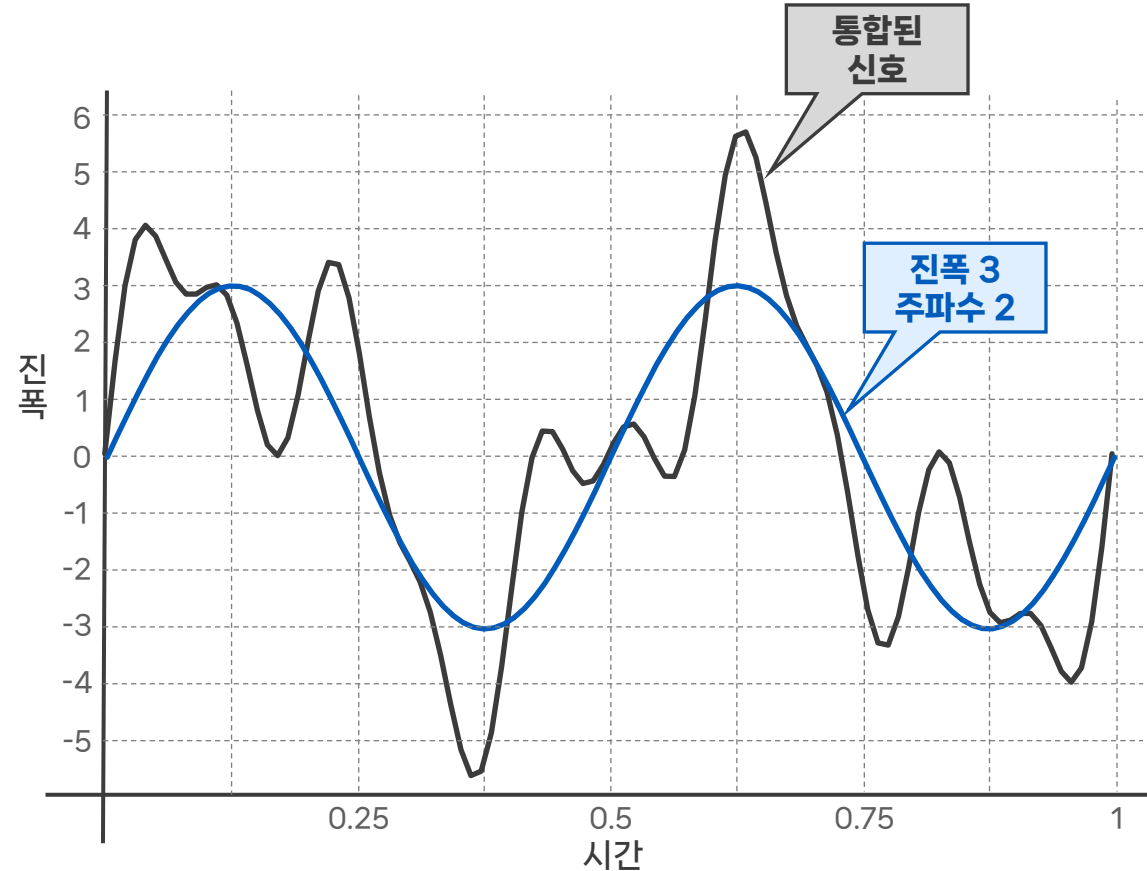
Fourier Transform

$$f(t) = a_0 + \sum_{n=1}^{\infty} [a_n \cos(n\omega t) + b_n \sin(n\omega t)]$$

$$a_0 = \frac{1}{T} \int_0^T f(t) dt$$

$$a_n = \frac{2}{T} \int_0^T f(t) \cos(n\omega t) dt$$

$$b_n = \frac{2}{T} \int_0^T f(t) \sin(n\omega t) dt$$





01 FFT(Fast Fourier Transform)


Fourier Transform

$$f(t) = a_0 + \sum_{n=1}^{\infty} [a_n \cos(n\omega t) + b_n \sin(n\omega t)]$$

$$b_n = \frac{2}{T} \int_0^T f(t) \sin(n\omega t) dt$$

$$3 \sin(2 \cdot 2\pi \cdot t)$$


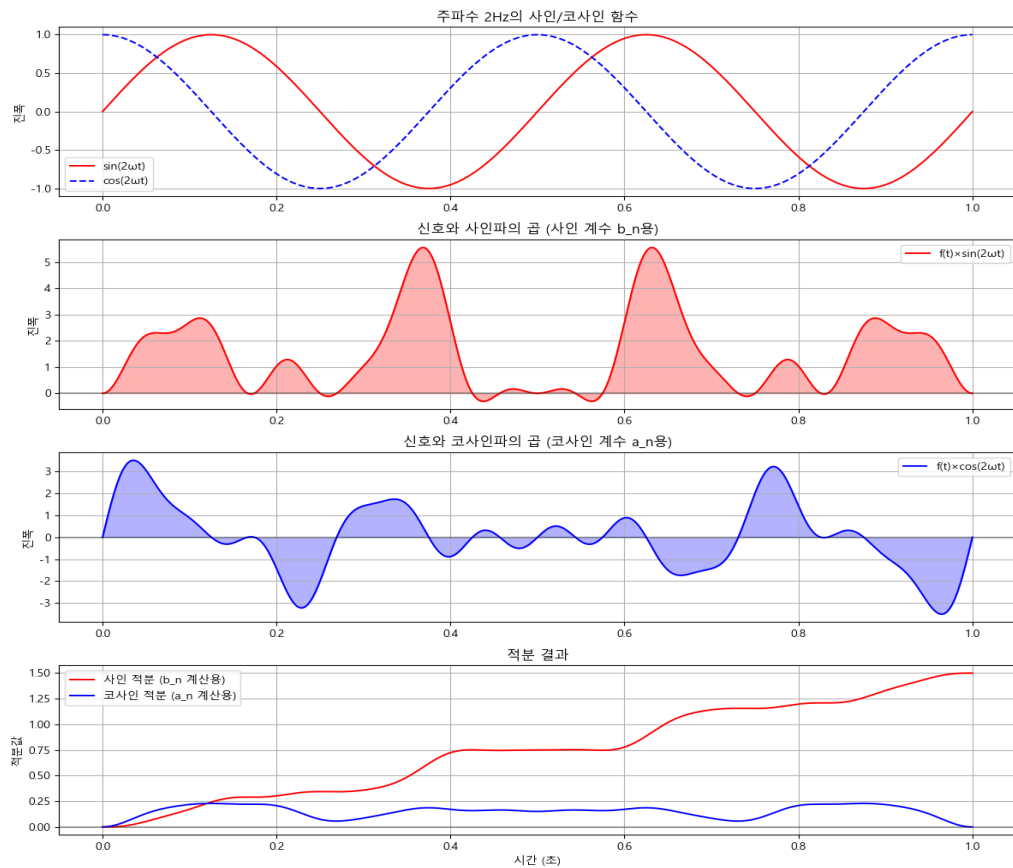
- ✓ 즉, sin 함수의 계수는 특정 주파수의 sin 함수와 신호 $f(t)$ 사이의 내적
- ✓ 신호에 특정 주파수 성분이 강하게 존재하면, 그 주파수의 sin/cos 함수와의 내적은 큰 값을 가짐





01 FFT(Fast Fourier Transform)

Fourier Transform






Background

01 FFT(Fast Fourier Transform)

Fourier Transform





02 Overview

TimesNet (ICLR, 2023)

- Multi-Periodicity 특성을 반영하기 위해 기존의 시간적 변동을 1D에서 2D로 확장하여 분석
- 이미지에 활용되는 모델을 backbone으로 사용하여 2D 변동성을 포착하는 방법을 제안
- 범용 기반 모델로 5개 주류 시계열 분석에서 SOTA 달성

Multi-periodicity

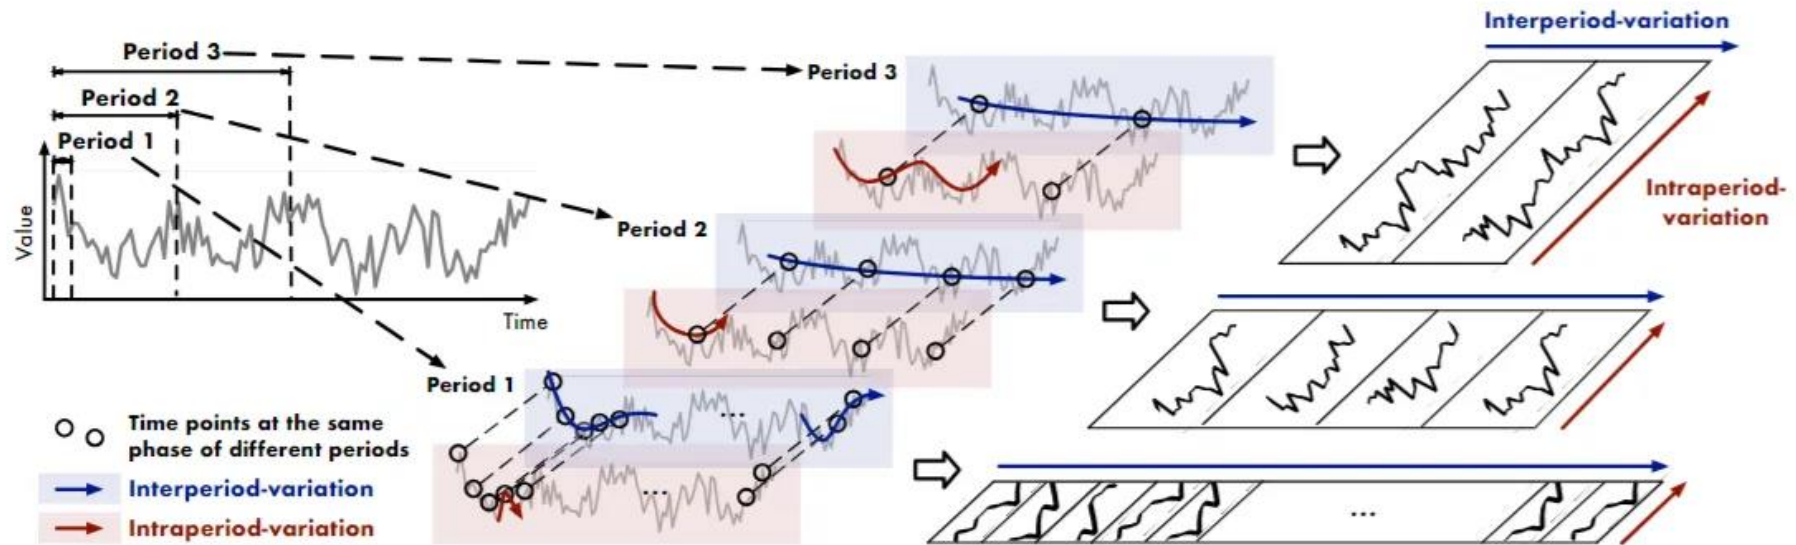
- 하나의 시계열 데이터 내에 여러 주기가 동시에 존재
예) 전력 소비 데이터는 일간(아침/저녁 피크), 주간(주중/주말 차이), 계절성(여름/겨울), 연간 주기를 포함
- 위의 예와 같이 여러 주기가 상호적으로 작용하여 복잡한 패턴을 형성
→ 따라서 이러한 특성을 모델링이 반영하면 예측 정확도를 향상 시킬 수 있음



02 Overview

TimesNet (ICLR, 2023)


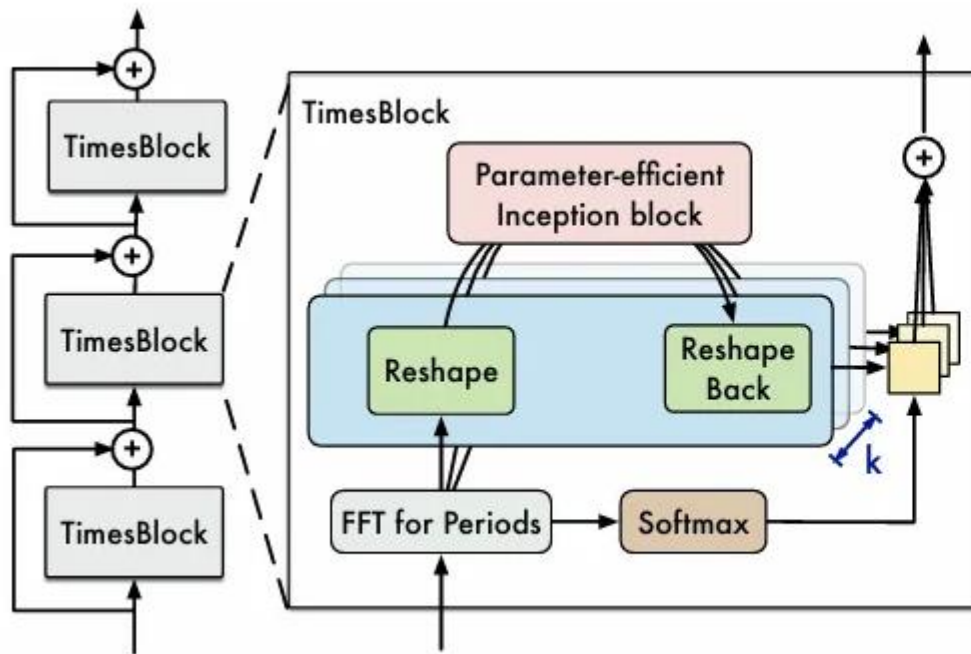
- Multi-Periodicity 특성을 반영하기 위해 기존의 시간적 변동을 1D에서 2D로 확장하여 분석
- 이미지에 활용되는 모델을 backbone으로 사용하여 2D 변동성을 포착하는 방법을 제안
- 범용 기반 모델로 5개 주류 시계열 분석에서 SOTA 달성





Overall architecture


- 3개의 TimesBlock으로 구성되며, residual한 방식으로 진행됨
- 2D 텐서를 inception 블록에 통과 시켜, multi-periodicity 특성을 포착






02 방법론

Transform 1D into 2D




- FFT를 통해 평균 진폭을 계산
- $A = Avg(Amp(FFT(X_{1D})))$
- 진폭 상위 k개 추출
- 2D 텐서로 재구축



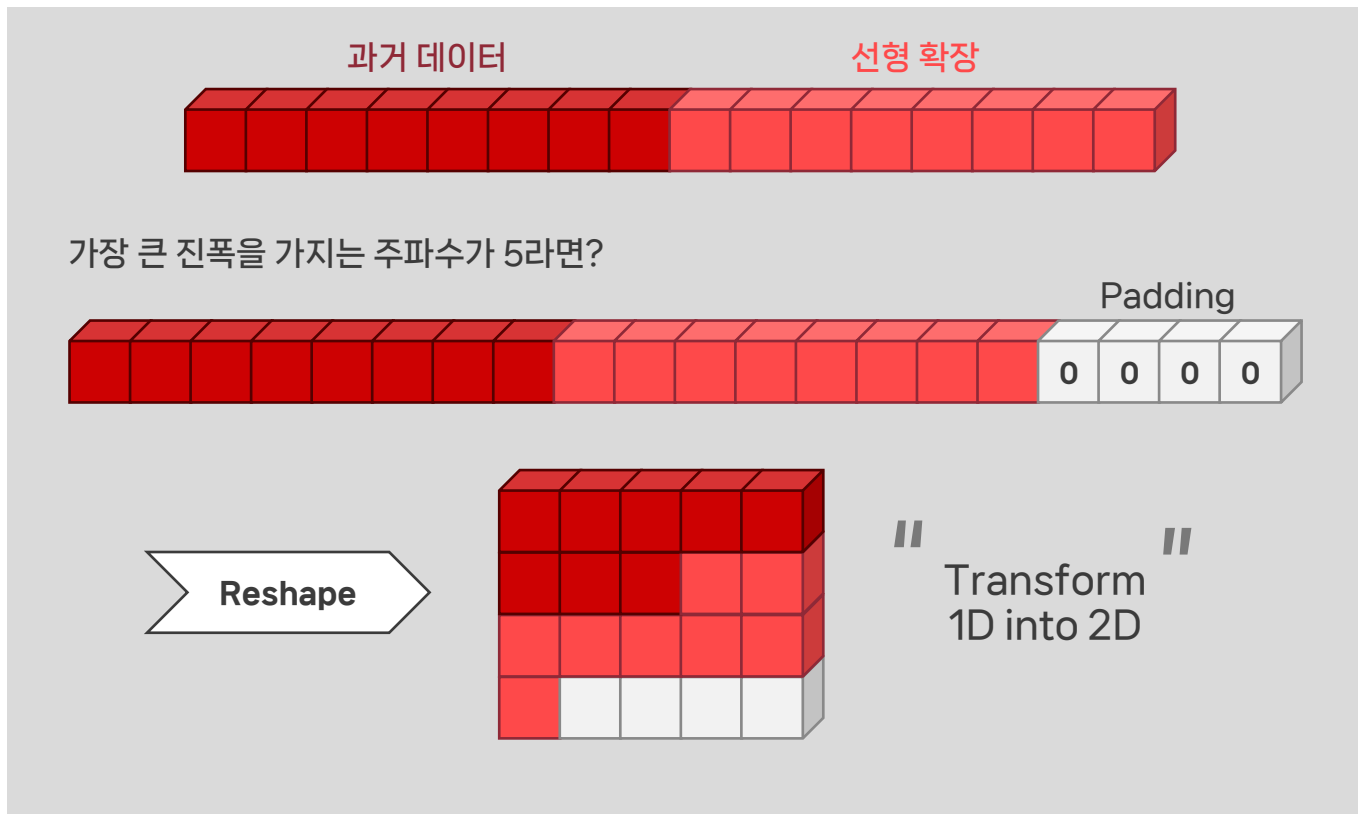


02 방법론

Transform 1D into 2D




- FFT를 통해 평균 진폭을 계산
- $A = Avg(Amp(FFT(X_{1D})))$
- 진폭 상위 k개 추출
- 2D 텐서로 재구축



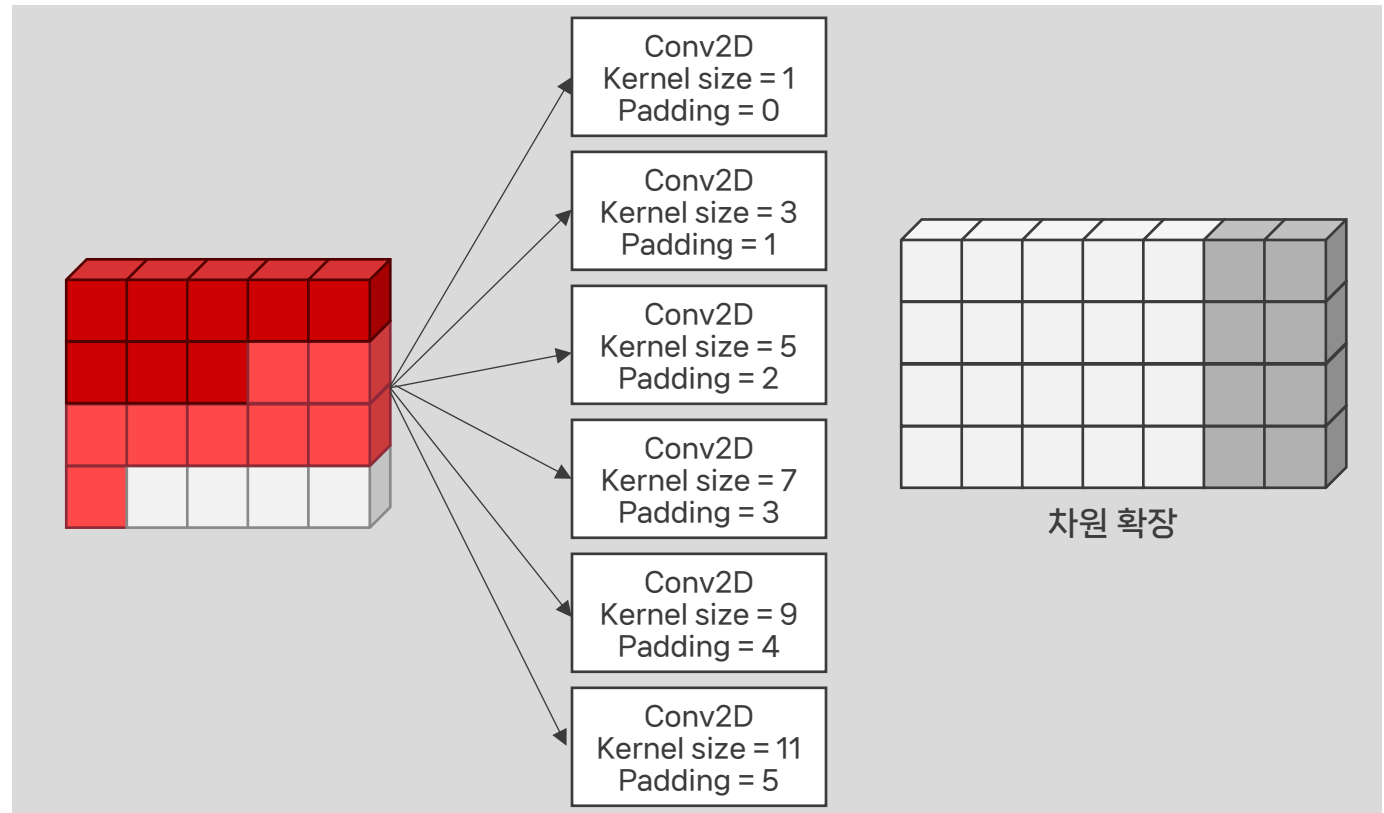


02 방법론

Inception Block




- 여러 크기의 커널을 병렬로 사용하여 다양한 스케일의 패턴 포착
- 서로 다른 주기의 텐서에 동일한 inception block을 공유하여 모델 크기를 효율적으로 유지

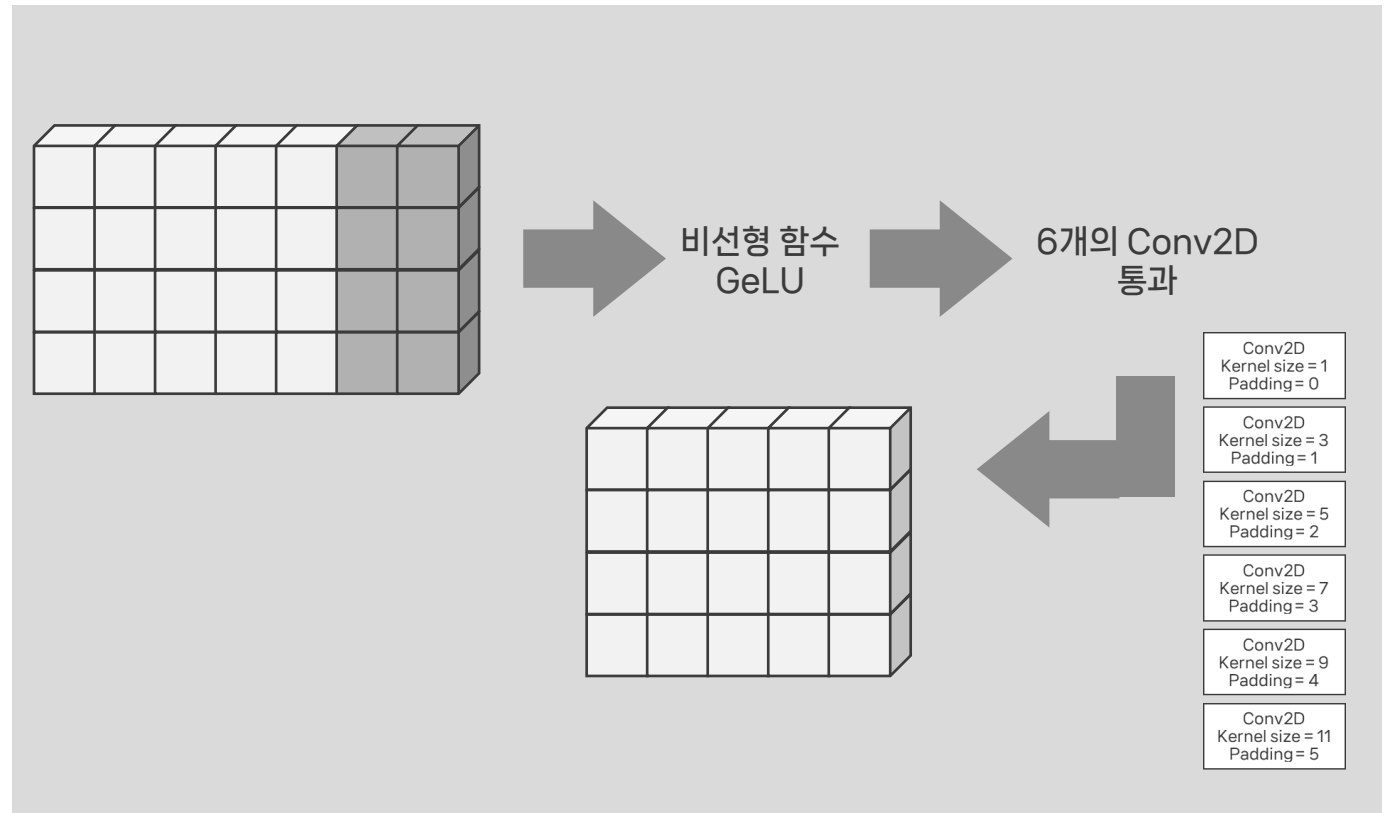




Inception Block




- 여러 크기의 커널을 병렬로 사용하여 다양한 스케일의 패턴 포착
- 서로 다른 주기의 텐서에 동일한 inception block을 공유하여 모델 크기를 효율적으로 유지







Adaptive Aggregation



- 최종적으로 추출된 K개의 텐서에 대해 진폭 값을 사용하여 가중 합계로 집계
- 진폭 값을 softmax 취하여 가중치로 사용

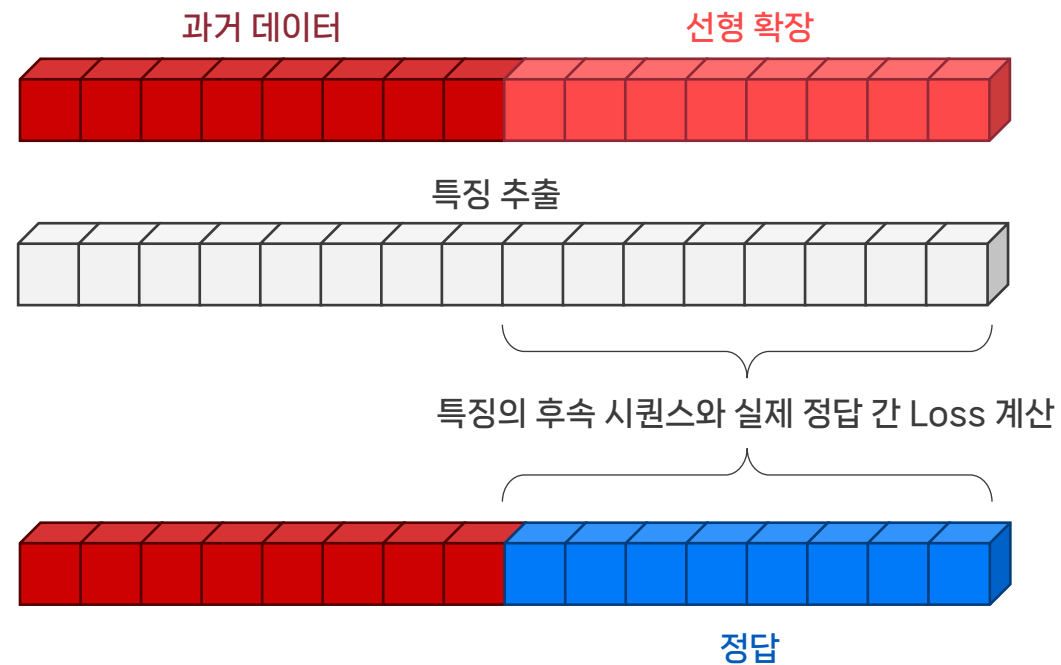
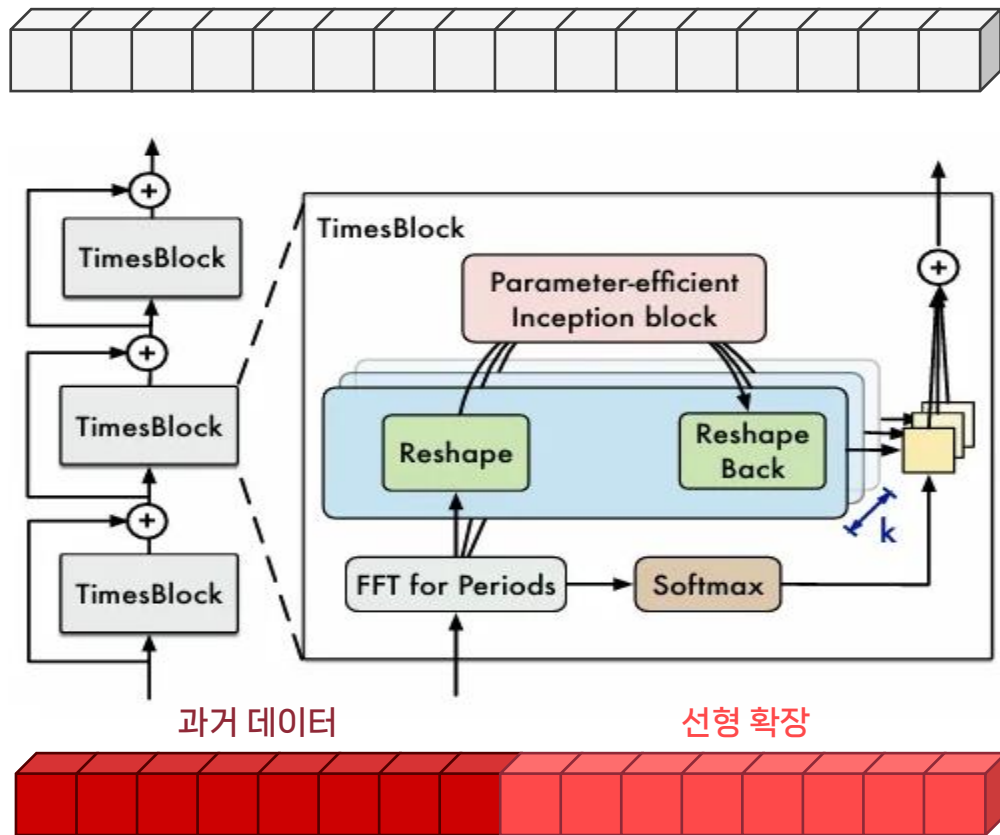
Reshape





02 방법론

Loss






03 Overview

TimeMixer (ICLR, 2024)

- 복잡한 패턴이 혼합된 시계열 분석을 위해 주로 시계열 분해(Decomposition)와 다중 주기성(Multi-periodicity) 분석이 널리 사용됨
- 하지만 시계열은 서로 다른 샘플링 스케일에서도 뚜렷한 시간적 변동을 보임







03 Overview

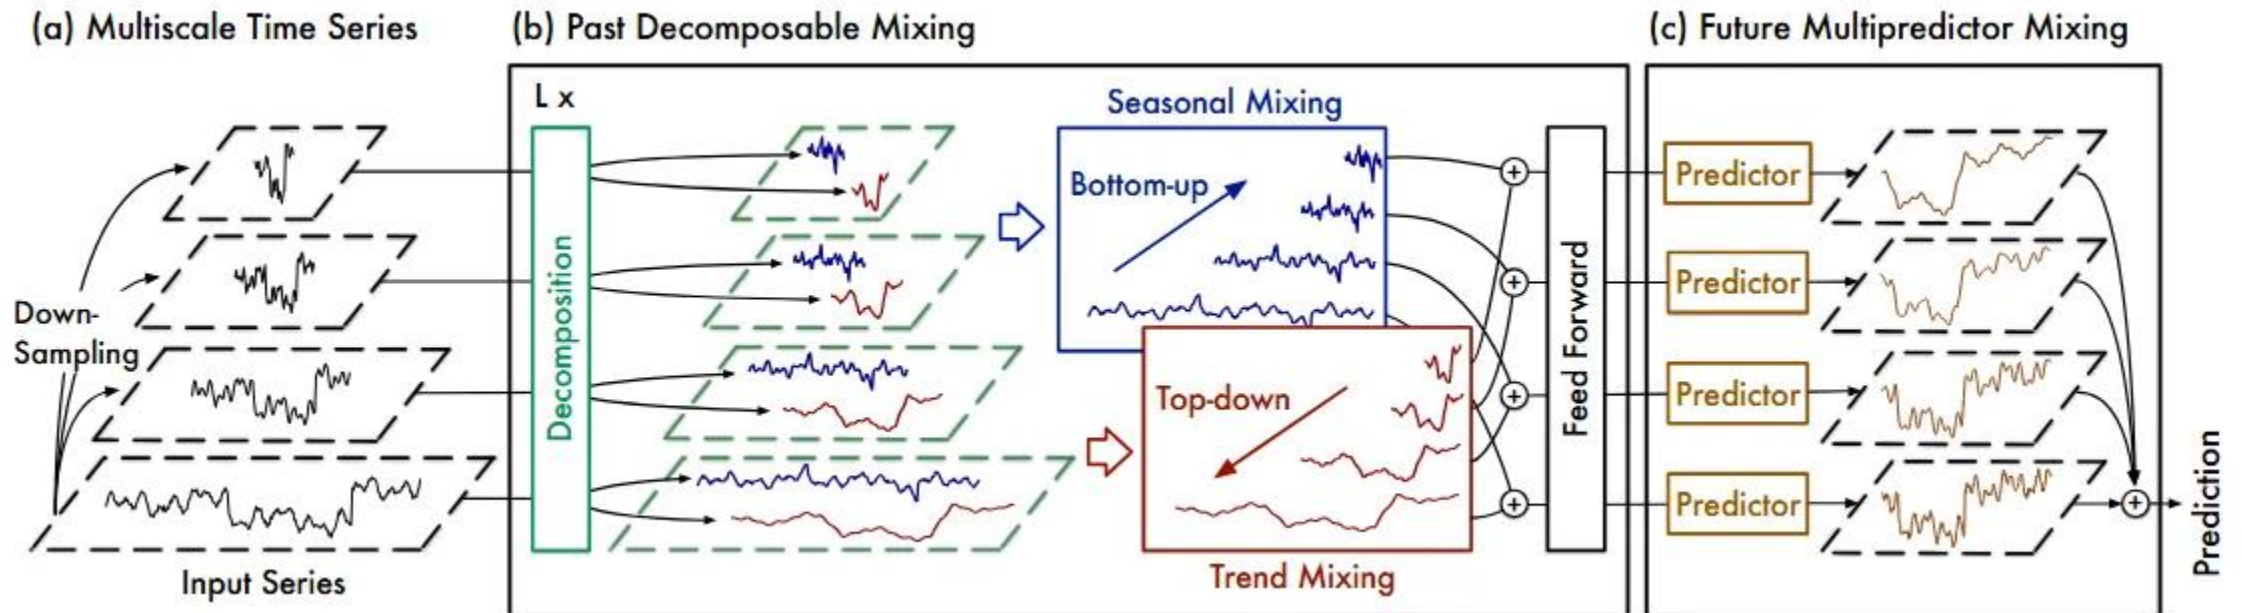
TimeMixer (ICLR, 2024)

- 서로 다른 샘플링 스케일의 시계열은 본질적으로 다른 특성을 보임
- 미세한 스케일에서는 상세한 패턴을 보여주고, 거시적 스케일에서는 전체적인 변동을 보여줌



Architecture

- 크게 다중 스케일을 생성하는 부분, 과거 정보에 대한 특징을 추출하는 부분, 예측기 부분으로 구성됨







Multiscale Time Series

- Down sampling을 통해 multi scale time series를 생성

(a) Multiscale Time Series

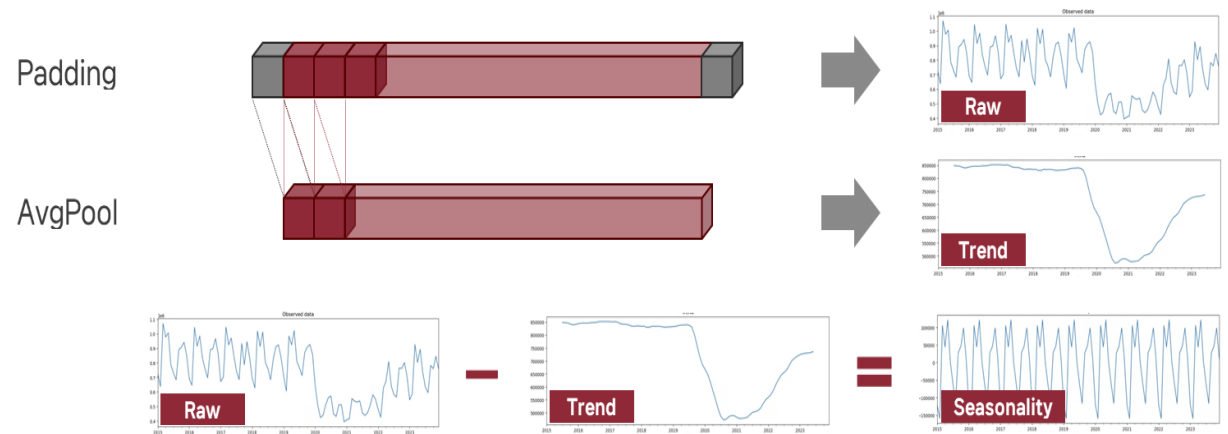





Past Decomposable Mixing

- 과거 정보에 대한 특징을 추출하는 부분
- Multi scale의 개별 scale에서도 모두 trend와 seasonality는 서로 다른 특성을 가짐

(b) Past Decomposable Mixing

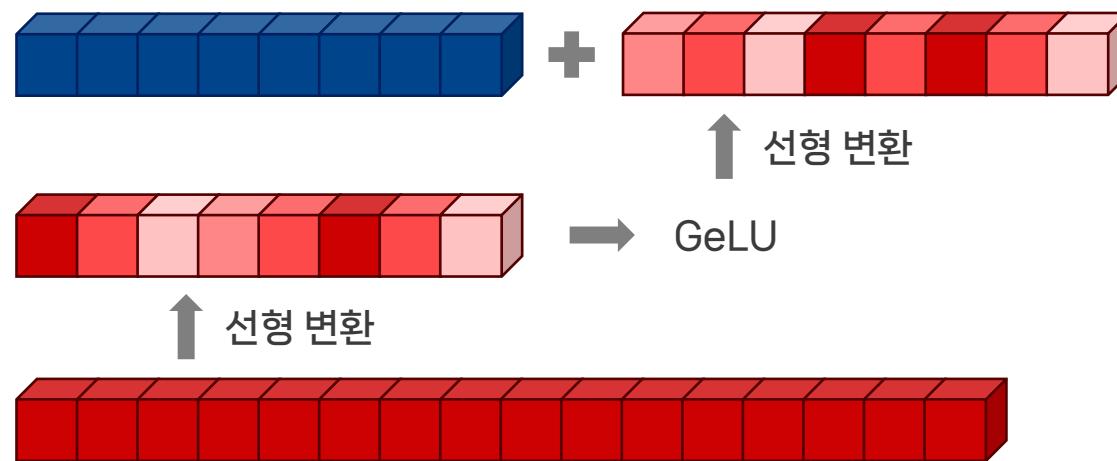





Past Decomposable Mixing

- 계절성 분석에서 더 큰 주기는 더 작은 주기들의 집합 → Bottom-up 방식의 접근

(b) Past Decomposable Mixing







Past Decomposable Mixing

- 추세 분석에서는 세부적인 변동이 거시적 추세를 포착하는데 노이즈로 작용할 수 있음 → Top-down 방식의 접근

(b) Past Decomposable Mixing

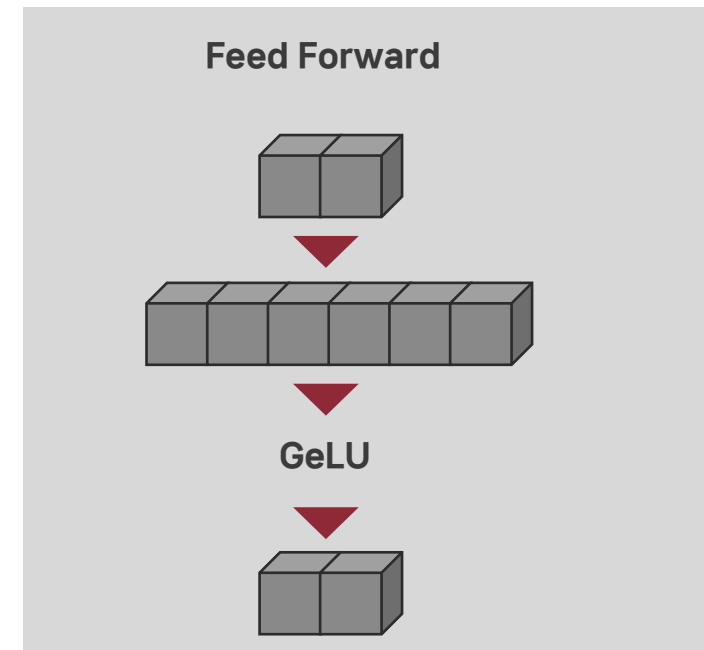

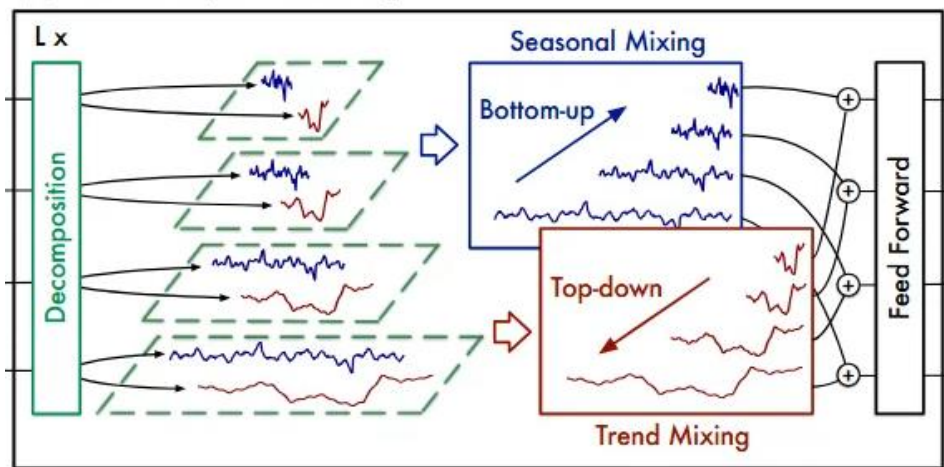




Past Decomposable Mixing

- Mixing이 완료되면 계절성분과 트렌드를 더한 후, Feed Forward 통과

(b) Past Decomposable Mixing

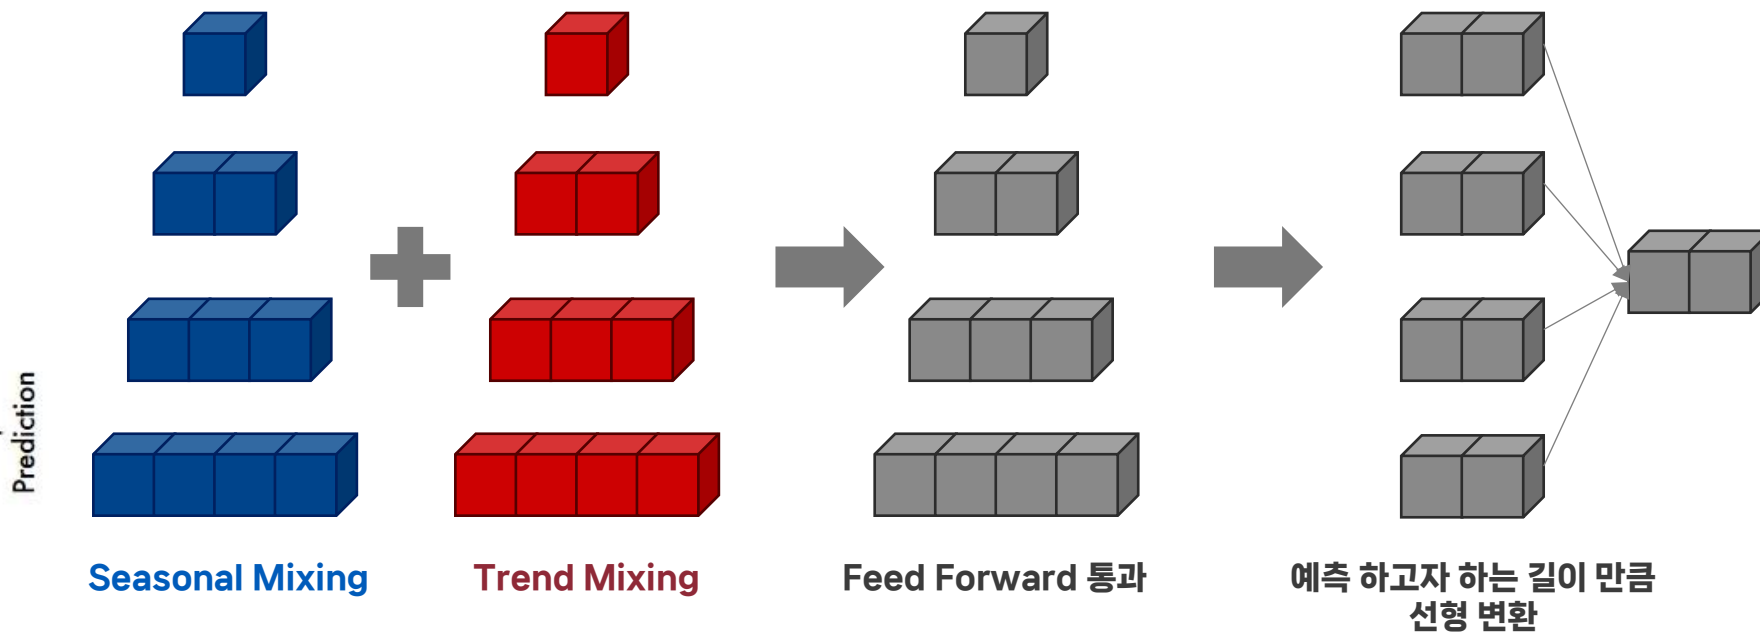
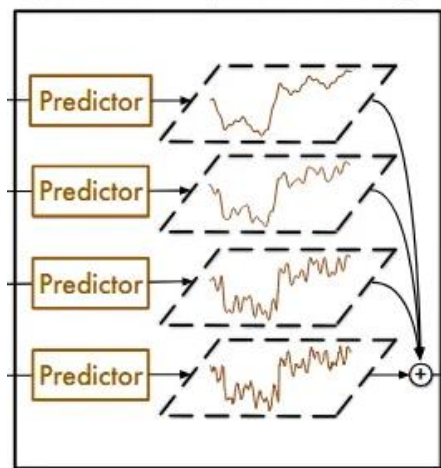




Future Multipredictor Mixing

- 각각의 스케일에서 미래 예측을 한 후, 이를 통합하는 과정

(c) Future Multipredictor Mixing



Conclusion

요약

- 시계열 분석은 오랫동안 decomposition을 기반으로 발전해옴
- 전통적인 시계열 분해가 추세와 계절성에 집중했다면, FFT를 활용한 현대적 접근법은 더 정교한 패턴 파악이 가능함
- TimesNet은 이러한 FFT 기반의 주요 접근법 중 하나이며, 시계열의 다양한 주기성을 효과적으로 모델링 함
- 최근에는 FFT를 넘어서 TimeMixer와 같이 데이터 수집 간격을 고려한 멀티 스케일 관점의 더 정교한 방법론도 제시됨

참고 문헌

- [1] Cleveland, R. B., Cleveland, W. S., McRae, J. E., & Terpenning, I. (1990). STL: A seasonal-trend decomposition. *J. off. Stat*, 6(1), 3-73.
- [2] Wu, H., Xu, J., Wang, J., & Long, M. (2021). Autoformer: Decomposition transformers with auto-correlation for long-term series forecasting. *Advances in neural information processing systems*, 34, 22419-22430.
- [3] Wu, H., Hu, T., Liu, Y., Zhou, H., Wang, J., & Long, M. (2022). Timesnet: Temporal 2d-variation modeling for general time series analysis. *arXiv preprint arXiv:2210.02186*.
- [4] Wang, S., Wu, H., Shi, X., Hu, T., Luo, H., Ma, L., ... & Zhou, J. (2024). Timemixer: Decomposable multiscale mixing for time series forecasting. *arXiv preprint arXiv:2405.14616*.

고맙습니다