

# 2024 암호분석경진대회 - 비밀분쇄기팀 1번 문제 풀이

## 1 세부 문제 1: Feed Polynomial 및 초기값이 주어졌을 때 LFSR 구현.

세부 문제 1을 해결하기 위해 Python 언어를 사용했다.

먼저 LFSR 의 feedback polynomial 을 관리하기 위해 Polynomial 클래스를 구현했다.  $GF(2)$  위에서 정의된 polynomial 이므로 1차원 binary 리스트를 coefficient 로 가진다. 문제 설명의 그림과 일치하도록 coefficient 는 가장 높은 차수부터 낮아지는 순서대로 저장하도록 했다. 구현한 코드의 일부분은 아래와 같다.

```
1 # lfsr.py
2 # GF(2) polynomial
3 class Polynomial:
4     # coeff is a list of coefficients, starting from the highest degree
5     # coeff = [p_m, p_m-1, p_m-2, ..., p_0]
6     # ex: x^3 + x + 1 -> Polynomial([1, 0, 1, 1])
7     def __init__(self, coeff):
8         assert coeff[0] == 1
9         self.deg = len(coeff) - 1
10        self.coeff = coeff
```

이후 Polynomial 클래스와 initial state (binary 리스트)를 초기화 입력으로 받는 LFSR 클래스를 구현했다. 문제 설명의 그림과 일치하도록 initial state 및 state 는 feedback 입력부터 출력 순으로 저장하도록 했다. step() 멤버 함수를 호출해 LFSR 의 다음 비트를 생성할 수 있고, generate\_n\_bits() 함수로 한번에  $n$  개의 bitstream 을 생성할 수 있다. 구현한 구현 코드의 일부분은 아래와 같다.

```
1 # lfsr.py
2 class LFSR:
3     # Initial states are stored in a list, from the highest degree to the lowest
4     # Like: [s_m-1, s_m-2, ..., s_0]
5     # At each step, the rightmost bit is returned, and the states are updated according to the polynomial
6     def __init__(self, poly, initial_states):
7         assert len(initial_states) == poly.deg
8         self.poly = poly
9         self.initial_states = initial_states
10        self.states = initial_states
11        self.len = len(initial_states)
12
13        def step(self):
14            ret = self.states[-1]
15            next_bit = 0
16            for i in range(self.len):
17                next_bit ^= self.poly.coeff[self.len - i] \
18                    * self.states[self.len - 1 - i]
19            self.states = [next_bit] + self.states[:-1]
20            return ret
21
22        def generate_n_bits(self, n):
23            self.states = self.initial_states
24            return [self.step() for _ in range(n)]
```

Polynomial 및 LFSR 클래스를 이용해 feedback polynomial이 (0,1,2,7,128)인 LFSR을 구현한 코드가 prob1.py 에 있다. 초기 값을 바꾸려면 line 11 의 initial\_states 를 설정하는 부분을 변경하면 된다.

```
1 # prob1.py
2 from lfsr import *
3 import random
4
5 deg = 128
6 poly_poplist = [0, 1, 2, 7, 128]
7 coeff = [1 if deg-i in poly_poplist else 0 for i in range(deg+1)]
8 poly = Polynomial(coeff) # x^128 + x^7 + x^2 + x + 1
9 print("Polynomial: ", poly)
10
11 initial_states = [random.randint(0, 1) for _ in range(deg)]
```

```

12 initial_states_str = ''.join([str(b) for b in initial_states])
13 print("Initial states: ", initial_states_str)
14
15 lsfr = LFSR(poly, initial_states)
16 bitstream = lsfr.generate_n_bits(1024)
17 bitstream_str = ''.join([str(b) for b in bitstream])
18 print("First 1024 bitstream: ", bitstream_str)

```

실행 결과는 다음과 같다.

```

$ python prob1.py
Polynomial: x^128 + x^7 + x^2 + x + 1
Initial states: 110100100110100 (... ) 1101111111000100110110110100100
First 1024 bitstream: 11100010000001101100010 (... ) 10011110001111011100000101111101011

```

## 2 세부 문제 2: LFSR 의 출력 bitstream 으로부터 주기를 찾아내는 DNN 학습.

### 2.1 학습 데이터셋 생성

다양한 polynomial 및 bitstream 길이에 대해 모델이 잘 작동하도록 하기 위해 무작위로 데이터를 생성했다. Feedback polynomial 의 최소 차수는 3, 최대 차수는 9 로 설정했다. 데이터셋을 생성할 때 bitstream 의 최소 길이는 32, 최대 길이는 1024로 설정했다.

하나의 데이터를 생성하는 과정은 다음과 같다.

1. Feedback polynomial 의 차수  $d$  를 [3, 9] 범위에서 무작위로 선택해 결정한다.
2. Feedback polynomial 의 계수들을 결정한다.  $x^d + p_{d-1}x^{d-1} + \dots + p_1x + 1$  에서  $p_{d-1}, \dots, p_1$  의 값을 각각 0 또는 1 중 무작위로 선택한다.
3. Initial state 를 결정한다.  $s_{d-1}, s_{d-2}, \dots, s_1, s_0$  의 값을 각각 0 또는 1 중 무작위로 선택한다.
4. 1.-3. 과정에서 얻은 LFSR 의 주기  $\tau$  를 계산한다. 이 과정은 brute-force 방식으로 같은 state 가 두 번 이상 반복될 때까지 bitstream 을 생성해 주기를 찾아낸다. LFSR 의 주기가 3보다 작거나, 512를 초과하면 (주기가 너무 길어 bitstream 이 최대 길이임에도 한 주기가 반복되지 못할 경우) 1. 로 돌아간다.
5. 생성할 bitstream 길이를  $[2\tau, 1024]$  사이에서 무작위로 결정한 뒤 해당 길이만큼 bitstream 을 생성한다.

위 과정을 반복해 총 32768 개의 데이터를 생성한 뒤, train, validation, test 데이터셋을 8:1:1 의 비율로 나누어 사용했다.

### 2.2 DNN 모델 구조 및 학습

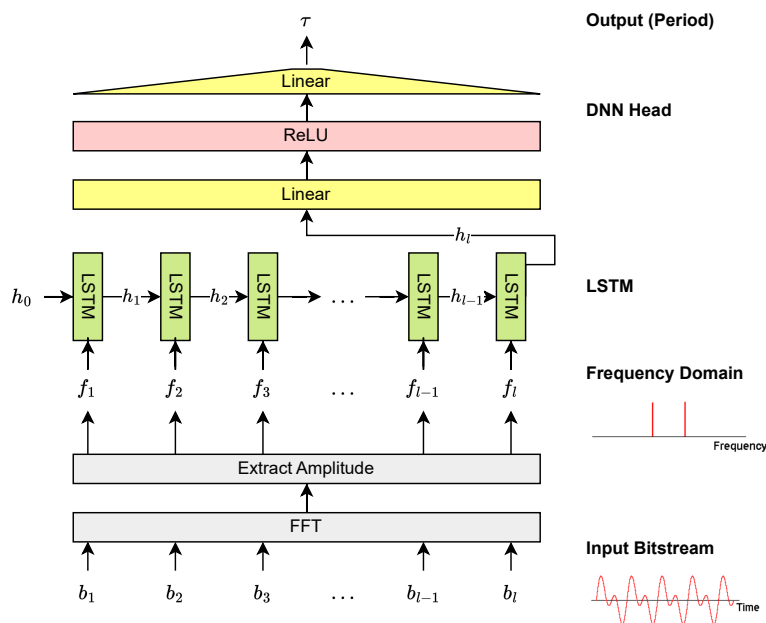


Figure 1: DNN 모델 구조

**모델 구조** Figure 1 에 사용한 DNN 모델 구조가 도식화되어 있다. 먼저, 입력 bitstream 에 Fast Fourier Transform (FFT) 를 적용해서 시계열 데이터를 time domain 에서 frequency domain 으로 변환한 뒤, amplitude 값을 취한다. 이렇게 변환된 데이터를 LSTM [1] 모델의 입력으로 넣은 다음 최종적인 hidden state  $h_l$  을 취한다. LSTM 의 마지막 hidden state  $h_l$  을 두 개의 Linear 레이어로 구성된 DNN head 에 통과시켜 scalar output 을 얻어낸다. Scalar output 이 실수 형태로 주어지므로, 이를 반올림해서 최종적인 bitstream 의 주기 값으로 사용한다.

LSTM 모델의 hidden vector 의 크기는 128로 설정했다. DNN head 의 첫 Linear 레이어의 크기는  $128 \times 128$  이고, 두번째 Linear 레이어의 크기는  $128 \times 1$  이다.

Table 1: DNN 학습을 수행한 시스템 정보.

|              |   |
|--------------|---|
| Motherboard  | ASRockRack GENOAD8X-2T/BCM                    |
| CPU          | 2 x AMD EPYC 9124 16-Core Processor           |
| Main Memory  | 8 x DDR4-2666 32GB                            |
| GPU          | 1 x NVIDIA Geforce RTX 4090                   |
| PCIe         | 16 x Gen3 lanes per GPU                       |
| OS           | Ubuntu 20.04.6 LTS (kernel 5.4.0-100-generic) |
| GPU Driver   | 550.54.15                                     |
| CUDA Version | 12.4  |

**모델 학습 환경 및 파라미터** 모델 학습은 총 150 epoch 을 진행했다. Optimizer 는 Adam 을 사용했다. Learning rate 기본값은 0.005,  $\beta_1 = 0.9$ ,  $\beta_2 = 0.95$ ,  $\epsilon = 10^{-5}$  으로 설정했다. Learning rate scheduler 는 LambdaLR 을 사용했다. Loss function 으로는 MSE (Mean Squared Error) 을 사용했다.

## 2.3 모델 학습 결과




Figure 2: 모델 학습 결과

Figure 2 에 모델 학습 결과가 나타나 있다. Training loss 가 떨어짐에 따라 validation accuracy 가 증가하는 경향이 잘 나타나 있다. Validation accuracy 가 가장 높은 모델을 최종 모델로 선정하고, 이를 이용해 test dataset 에 성능을 평가한 결과, 최종적인 test accuracy 는 87.25% 를 달성할 수 있었다. DNN 모델이 3278 개의 bitstream 데이터 중 2860 개의 주기를 정확히 찾아낸 것이다.

## 3 소스 코드 설명

**사용한 파이썬 패키지 버전** 개발 및 모델 학습에 Python 3.10.14, PyTorch 2.4.0, Pandas 2.2.2 를 사용했다.

**Polynomial 및 LFSR 구현 코드** lfsr.py 는  $GF(2)$  polynomial 및 LFSR 을 구현한 소스 코드이다. 별도의 외부 패키지를 사용하지 않고 구현하였다. 구현을 테스트하는 코드는 prob1.py 에 있다.

**데이터셋 생성 코드** generate\_dataset.py 는 LFSR 데이터셋을 생성해 csv 파일로 저장하는 소스 코드이다.

python generate\_dataset.py 와 같이 실행 가능하며, 프로그램 실행 결과로 train.csv, val.csv, test.csv 의 세 파일이 생성된다.

모델 학습 코드 `train.py` 에 모델 구조 정의 및 학습 코드가 구현되어 있다.

`python train.py` 와 같이 실행 가능하며, 학습 결과는 csv 형태로 stdout 에 출력되고, 학습된 모델 파라미터는 `model.pth` 에 저장된다. 실행 예시는 아래와 같다.

```
$ python -u train.py | tee train_log.csv
epoch,train_loss,val_acc
0,15.647392200842136,0.2268009768009768
1,9.17580356365297,0.28357753357753357
2,14.240020184400604,0.10531135531135531
3,4.716839269312417,0.3324175824175824
(...)
96,0.2460476072823129,0.8601953601953602
97,0.24704658643501562,0.8525641025641025
98,0.240397003365726,0.858058608058608
99,0.2431693112704812,0.8635531135531136
Training done
Best validation accuracy: 87.00%
```

결과 csv 파일을 받아 도식화하는 프로그램은 `plot.ipynb` 에 구현되어 있다.

## 4 학습된 모델 평가 코드

`test.py` 에 학습된 모델을 테스트 데이터셋으로 평가하는 코드가 구현되어 있다. 학습된 모델 파라미터를 `model.pth` 에서 읽어 오고, 테스트 데이터를 `test.csv` 에서 읽어온 뒤, 전체 bitstream 데이터 중 정확히 주기를 추측한 개수를 stdout 으로 출력한다. `test.csv` 파일 내용으로 bitstream 데이터를 `seq` 열에, 주기를 `period` 열에 제공해 주면 된다. 본 보고서 작성에 사용된 예시 `test.csv` 파일을 함께 제출한다. 실행 예시는 다음과 같다.

```
$ python -u test.py
Test accuracy: 87.25 %, 2860 / 3278
```

## References

- [1] Alex Graves and Alex Graves. Long short-term memory. *Supervised sequence labelling with recurrent neural networks*, pages 37–45, 2012.