



HANNES HAGMAR

MASKININLÄRNINGSBASERAD REALTIDSSTYRNING
AV FÖRNYELSEBARA OCH SÄKRA ELKRAFTSYSTEM



CHALMERS
UNIVERSITY OF TECHNOLOGY

PROJEKT

- **Löptid:** 1 oktober 2021 – 30 september 2022
- **Projektgrupp:** Hannes Hagmar (Chalmers), Anh Tuan Le (Chalmers), Robert Eriksson (Svenska kraftnät)
- **Referensgrupp:** Massimo Bongiorno (Chalmers), Marina Papatriantafilou (Chalmers), Ola Carlson (Chalmers), Per Norberg (Vattenfall), Mattias Persson (RISE), Ferruccio Vuinovich (Göteborg Energi)



BAKGRUND

Stort behov av mer överföringskapacitet

- Att bygga ut elnät är kostsamt och tar tid
- Kan vi utnyttja befintlig infrastruktur så kan det spara oss mycket resurser

Mer komponenter som styrs genom kraftelektronik

- Snabbare dynamik
- Existerande övervaknings- och styrsystem kan i framtiden bli för långsamma

ÖVERVAKNING OCH STYRNING

Säkert kraftsystem: N-1 kriteriet

- Övervaka säkerhetsmarginaler
- Aktivera olika handlingar för att göra systemet säkert

Behöver även metoder i de (ovanliga) fall systemet blir ostabilt

- Detektera och stabilisera systemet så snabbt som möjligt

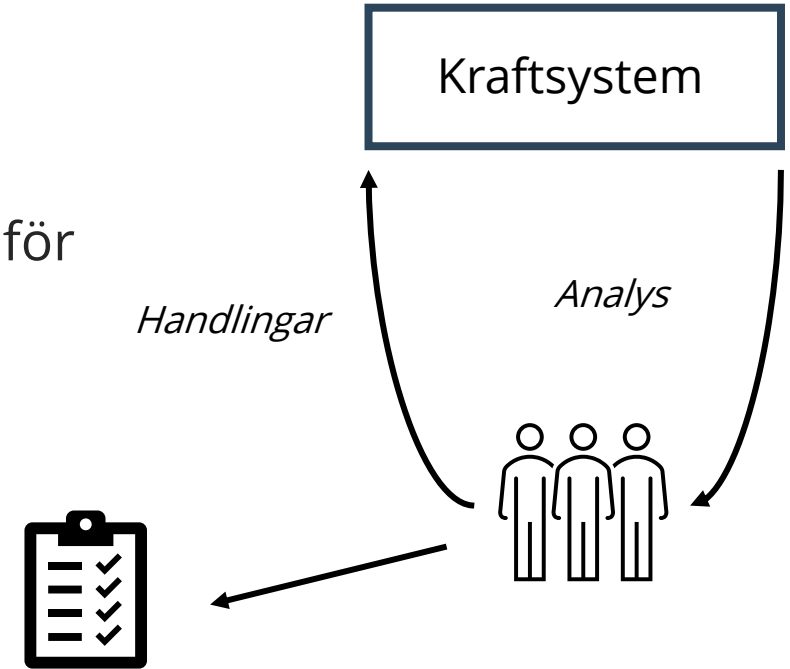
KLASSISK BESTÄMMNING AV STYRREGLER

STEG:

1. Kör olika simuleringar där olika scenario testas
2. Analysera effektiviteten för olika handlingar
3. Utveckla tabeller där olika handlingar är rankade för olika situationer

Nackdelar:

- Baseras ofta på ett mycket begränsat antal scenario
- Generellt långt från optimal handlingar



Tabell med olika handlingar

PROJEKTMÅL

- Utveckla ett optimeringsbaserat styrsystem för realtidsstyrning
 - Metod anpassad för *förebyggande* styrning: bibehålla tillräckliga säkerhetsmarginaler
 - Metod anpassad för *akut* styrning: stabilisera elnätet vid eventuella större (N-2) störningar
- Styrbara handlingar inkluderar framtida systemtjänster från distributionsnät
- Utvärdera olika typer av osäkerheter: mätfel, osedda driftscenarier
- Utvärdera möjligheterna att anpassa de utvecklade system så att de även kan användas för styrning inom distributionssystem

FÖRSTÄRKNINGSINLÄRNING

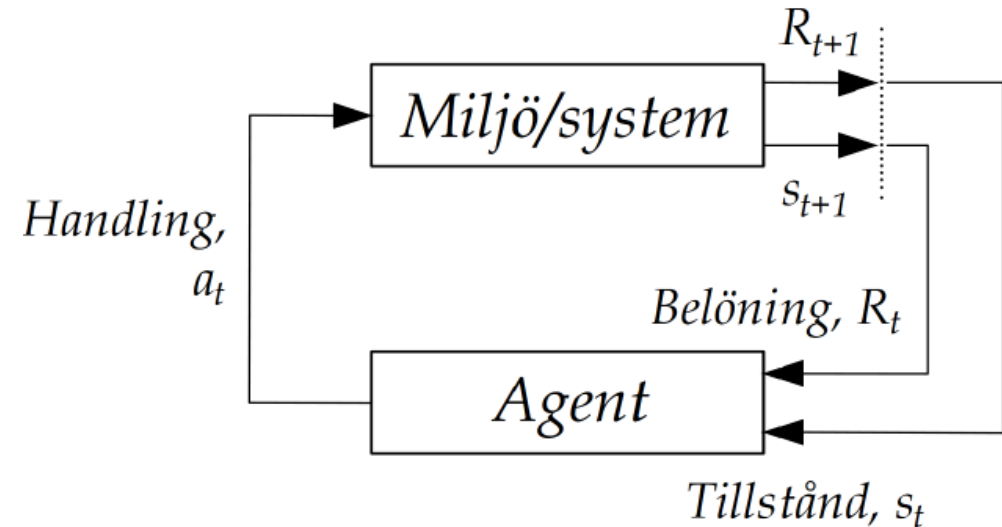


CHALMERS
UNIVERSITY OF TECHNOLOGY

TEORI: FÖRSTÄRKNINGSINLÄRNING

Förstärkningsinlärning (reinforcement learning, eng.: RL): maskininlärning anpassad för styrning
Markoviansk beslutsprocess: ett matematiskt ramverk för att modellering styrproblem

- **Agent:** ansvarig för att ta olika handlingar
- **Miljö:** systemet vi försöker styra
- **Tillstånd:** vår kunskap om systemet
- **Styrpolicy (π):** från tillstånd till handling
 - Deterministisk: $\pi(s): \mathcal{S} \rightarrow \mathcal{A}$
 - Stokastisk: $\pi(a|s): \mathcal{S} \rightarrow P(\mathcal{A})$



Träning av en RL-agent

1. Agenten tar olika handlingar (som beror på tillståndet)
2. Handlingar ger upphov till belöningar och nya tillstånd
3. Bra handlingar belönas, dåliga straffas


Mål: Hitta en optimal styrpolicy



DJUP FÖRSTÄRKNINGSINLÄRNING

Varför behöver vi "djup" förstärkningsinlärning?

- Oftast väldigt många tillstånd
- Vi behöver en metod som gör att vi kan gå från tusentals tillstånd till en viss handling
- Neurala nätverk är mycket effektiva för sådana "funktionsapproximeringar"!

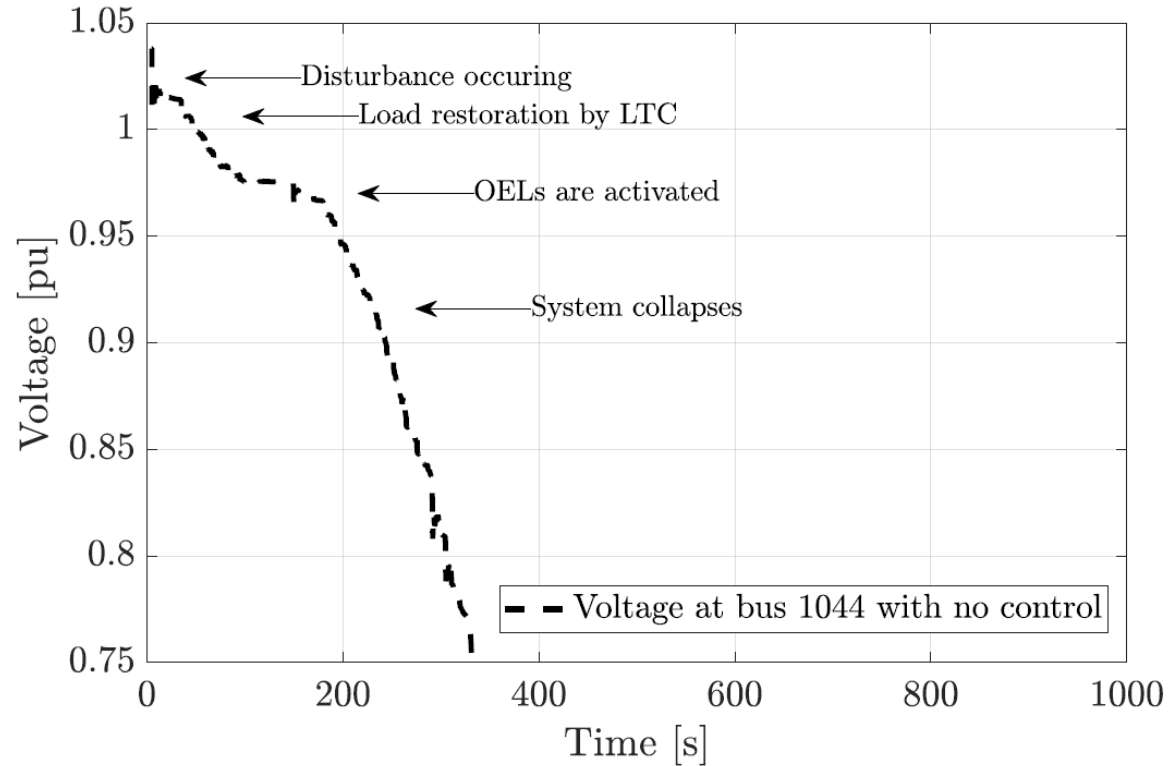


APPLIKATION 1: AKUT STYRNING



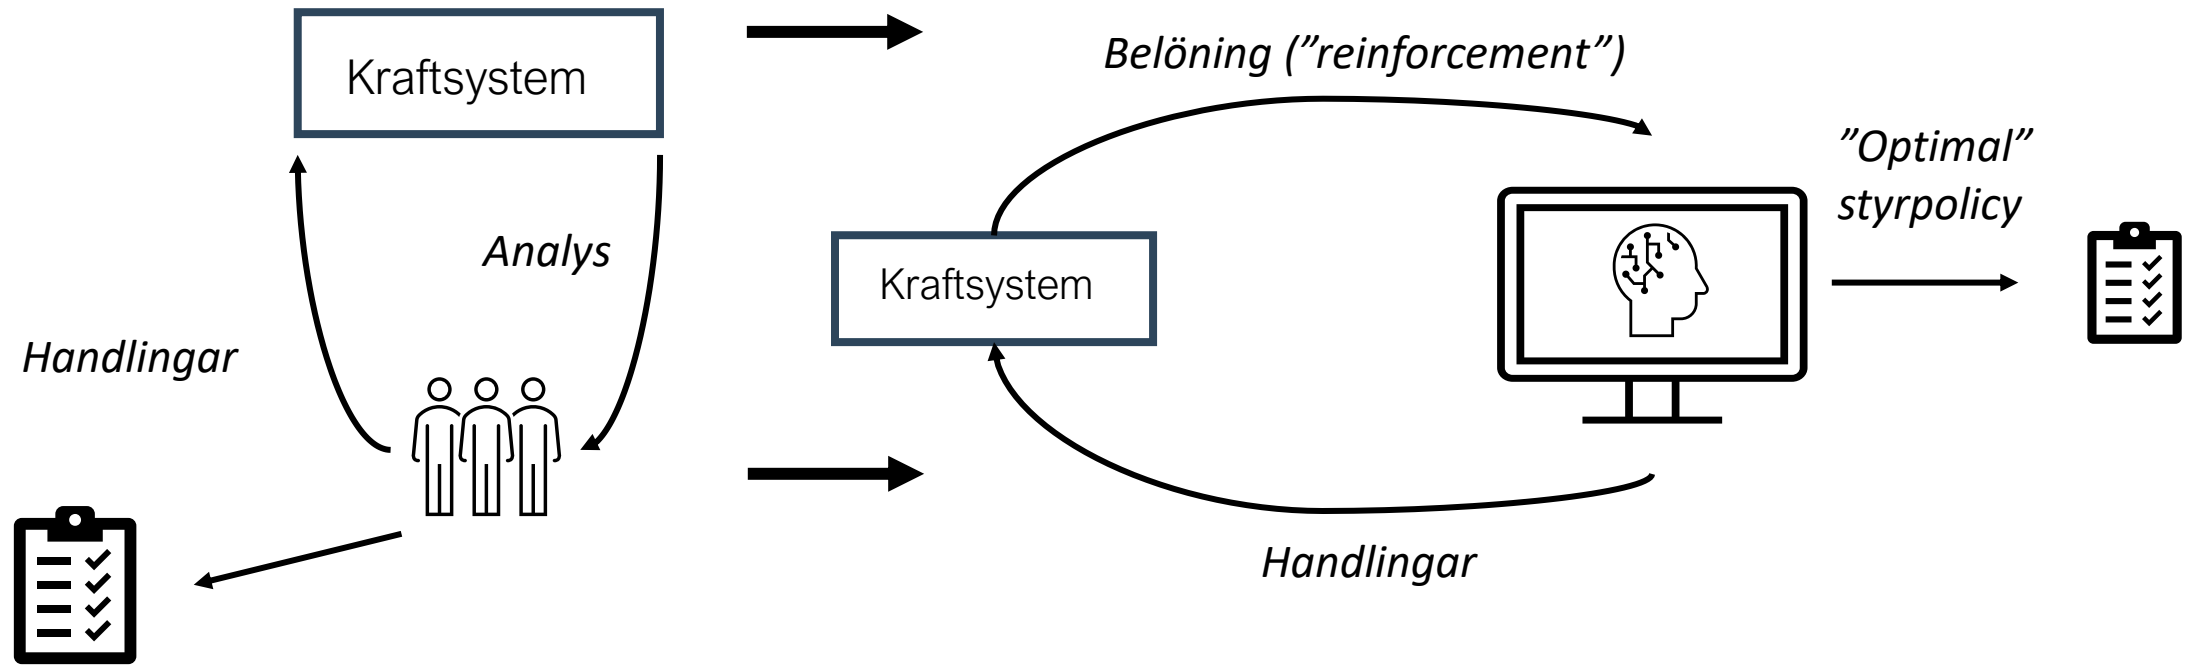
CHALMERS
UNIVERSITY OF TECHNOLOGY

LÅNGSAM SPÄNNINGSINSTABILITET



- Mer komplext att hantera än man kan tro
1. Snabb detektering av instabilitet
 2. Vilka handlingar ska aktiveras?

FROM KLASSISK STYRNING TILL DRL



TRÄNINGSMETODIK

Använde det modifierade "Nordic 32" test systemet

- Generera stor mängd träningsdata i form av dynamiska simuleringar
- Varierade last och produktion
- Introducerade slumpmässiga störning

DRL-agenten tar olika handlingar

- Var 5e sekund så utvärderar DRL-agenten systemet och tar olika handlingar
- Kan aktivera lastreduktion vid olika bussar i system
- Lastreduktionen fås från underliggande distributionsnät och modelleras (implicit) som styrning från lastflexibilitet/energilagringssystem som upphandlats på en stödtjänstmarknad

Belöningar och kostnader

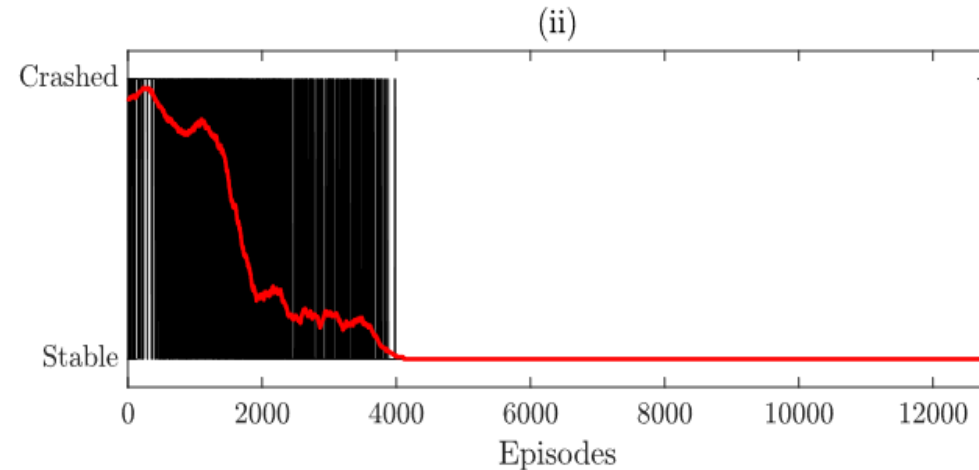

- Alla handlingar har en kostnad
- Om systemet krashar så får DRL-agenten en mycket hög negativ belöning

Mål: Stabilisera systemet till lägsta kostnad

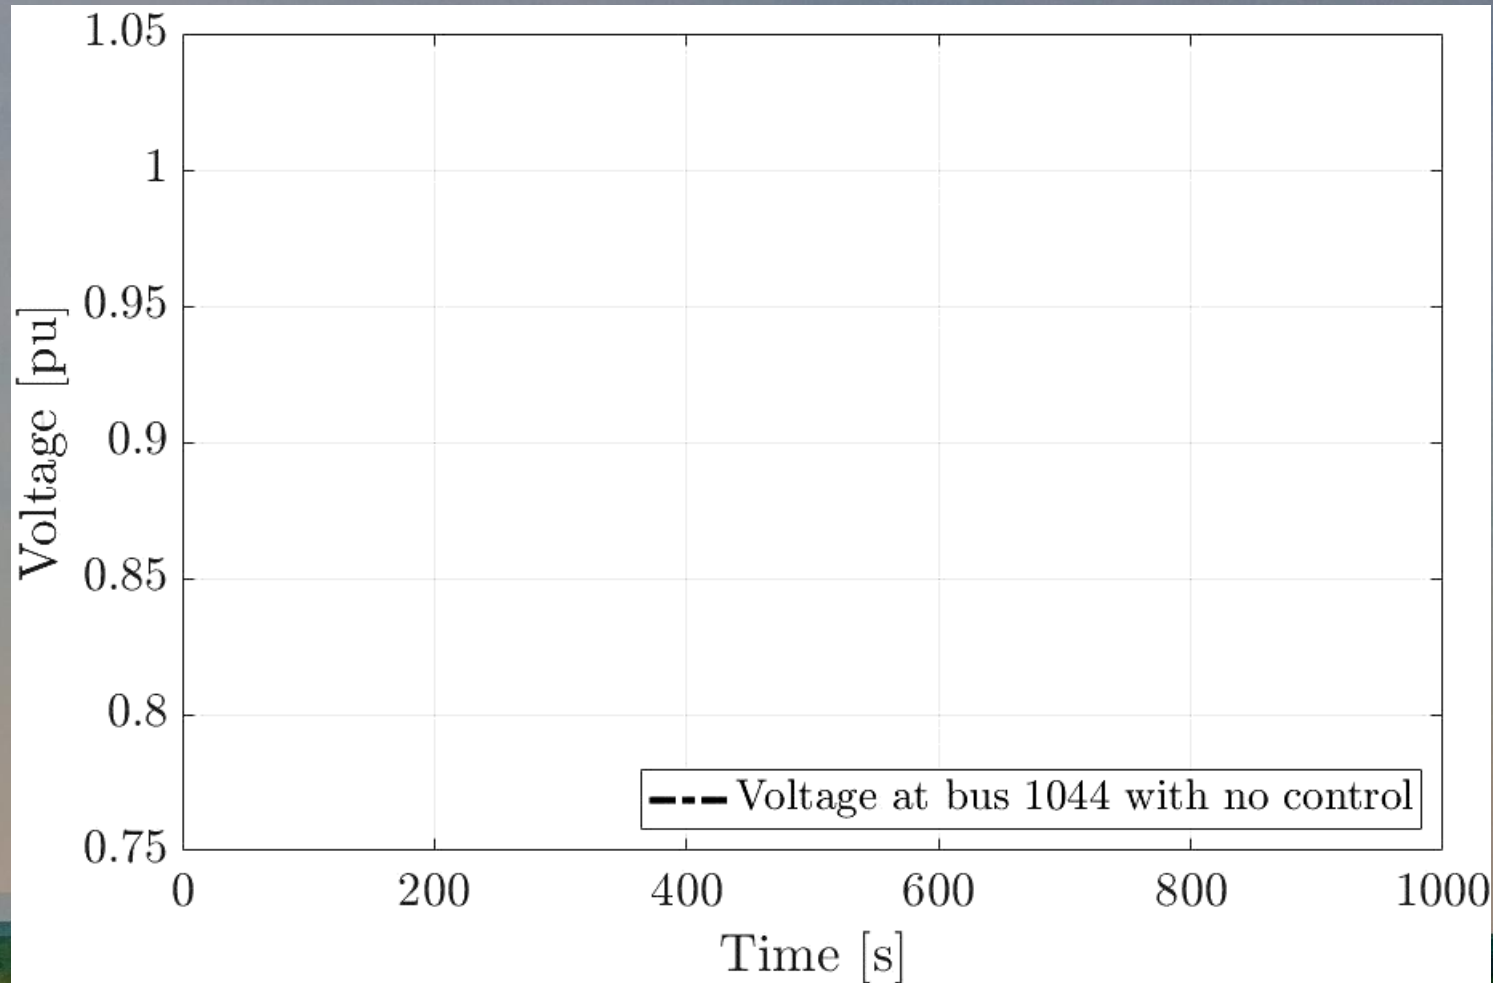
TRÄNINGSRISULTAT

Tränades på 13 000 dynamiska simuleringar

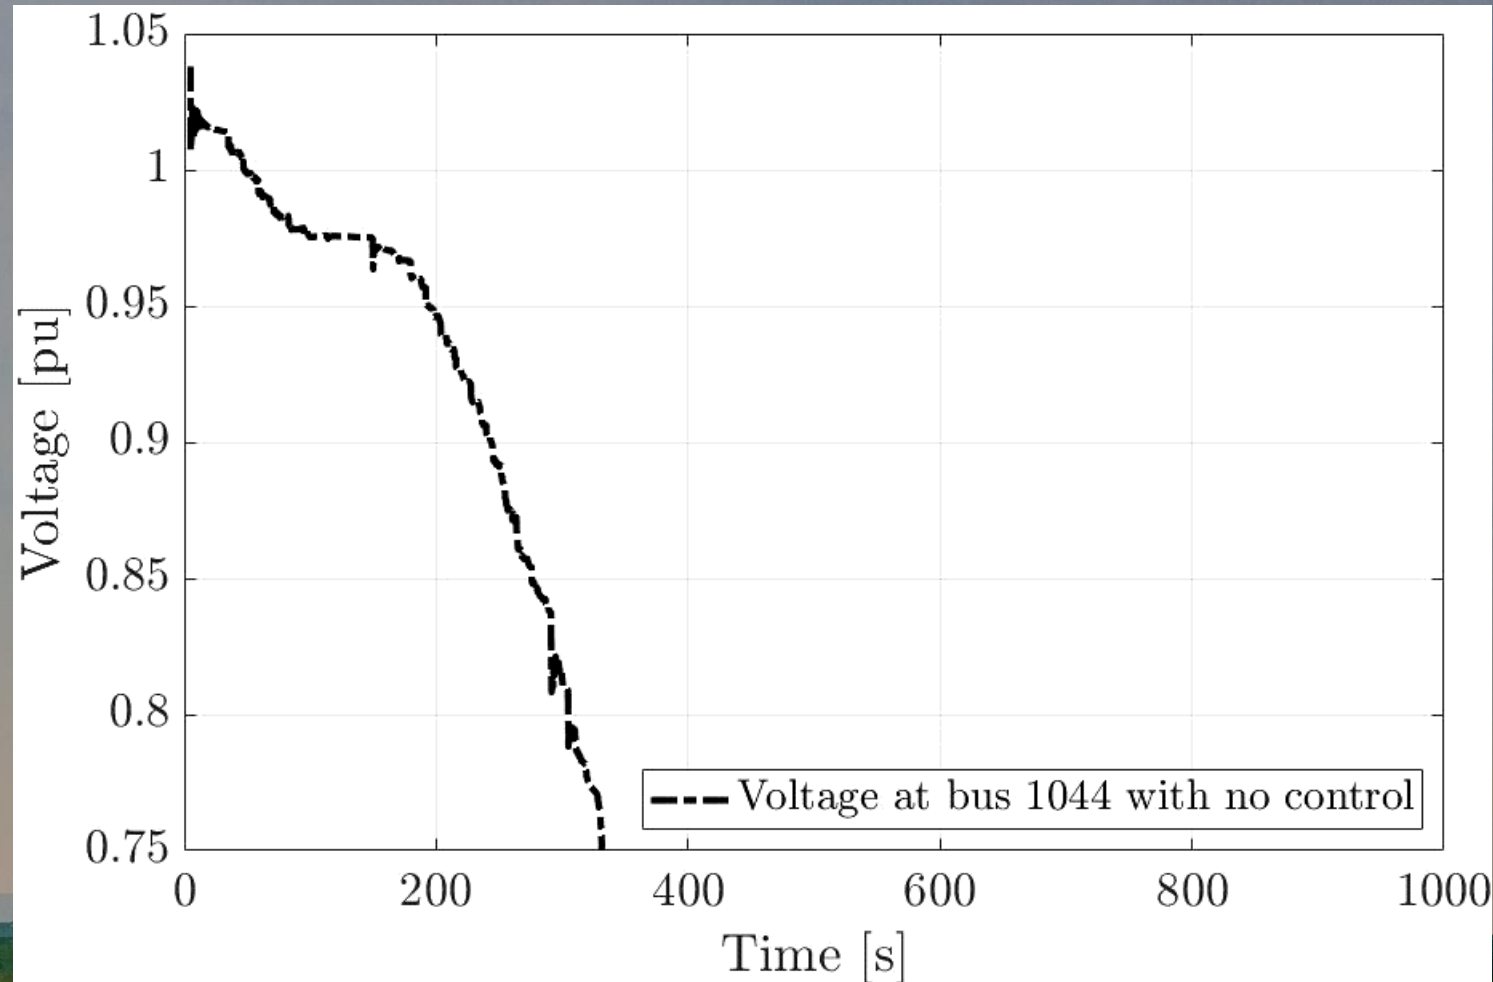
- DRL-agenten lär sig snabbt hur systemet ska stabiliseras
- Styrningen optimeras genom att agenten lär sig hur mycket lastreduktion som ska aktiveras i varje scenario



EXEMPEL: INGEN STYRNING




EXEMPEL: TVINGAD LASTBORTKOPPLING



**TOTALT 100 MW LAST
KOPPLAS BORT SÅ FORT
NÅGON
SPÄNNINGSMAGNITUD
UNDERSTIGER 0.9 pu**

EXEMPEL: DRL-STYRNING




JÄMFÖRELSE I LASTBORTKOPPLING

Signifikant lägre nivå av lastbortkoppling krävs med DRL-styrningen

200 MW för tvingad lastbortkoppling

~ 90 MW med DRL-styrning



PRESTANDA FÖR OLIKA TESTSETS

Testset 1: samma som DRL-agenten tränats på

Testset 2: nya last/produktionsscenarion

Testset 3: ny typ av störning

TABLE II
AVERAGE PERFORMANCE REQUIRED FOR DIFFERENT TEST SETS AND CONTROL METHODS.

	Mean total reward per episode		Difference [%]
	<i>DRL control</i>	<i>Load shedding</i>	
Test set 1	-37.9	-86.7	128.6 %
Test set 2	-36.5	-114.2	213.9 %
Test set 3	-16.7	-22.3	33.5 %

TABLE III
AVERAGE LOAD CURTAILMENT REQUIRED FOR DIFFERENT TEST SETS AND CONTROL METHODS.

	Average load curtailment [MW]		Difference [%]
	<i>DRL control</i>	<i>Load shedding</i>	
Test set 1	190.9	560.0	193.4 %
Test set 2	166.1	597.0	259.4 %
Test set 3	124.5	144.0	15.7 %

SAMMANFATTNING

Samma angreppssätt användes även för den *förebyggande* styrningen

- Ger systemoperatörer ett sätt att i realtid aktivera optimerade handlingar för att stabilisera elnäten och säkerställa att det är driftsäkert
- Ökar möjligheten att köra elnäten närmare de faktiska gränserna med bibehållen stabilitet

Utmaningar finns! Bland annat:

- Robusthet mot osedda driftpunkter
- Kräver väldigt stora (simulerade eller verkliga) datamängder

ANPASSNING TILL STYRNING PÅ DISTRIBUTIONSNETSNIVÅ



CHALMERS
UNIVERSITY OF TECHNOLOGY

STORA SKILLNADER I BEHOV OCH MÖJLIGHETER

Styrning på distributionsnättnivå har helt andra behov och möjligheter för DRL-styrning

Mätsystem

- Färre mätningar och lägre upplösning
- Nya (och redan införda) krav på mätning kommer att underlätta för databaserade styrmetoder i framtiden
- Styrmålen har lägre krav (främst statistiska problem på distributionsnät)

Exempel på handlingar

- Styrning av aktiv och reaktiv effekt från lokala produktionssystem
- Styrning av lindningsomkopplare på transformatorer
- Frånkoppling av laster
- Styrning av lastefterfrågefleksibilitet
- Styrning av reaktiva shuntar
- Styrning av batterisystem / energilagring

TVÅ FALLSTUDIER

- 1) Styrning av efterfrågefleksibilitet
- 2) Spänningsreglering

För varje fallstudie diskuteras

- Utformning av "Markovianska beslutsprocesser" (grunden i förstärkningsinlärning)
 - Handlingar
 - Tillstånd
 - Belöningar
 - Dynamik för tillståndsövergångar och diskonteringsfaktor
- Typ av DRL-algoritm och datagenerering
- Tidigare studier
- Sammanfattning på utmaningar och praktiska aspekter

SLUTSATSER

- DRL har potential att signifikant förbättra nuvarande metoder för styrning på elnät
 - Realtidsstyrning
 - Optimerade handlingar
- Många utmaningar kvarstår – forskningen inom ämnet är ganska nytt fortfarande
- Många applikationer inom distributionsnät finns att utforska



FRÅGOR?



CHALMERS
UNIVERSITY OF TECHNOLOGY